



Modelo de propagación para un entorno urbano que identifica las oportunidades espectrales para redes móviles de radio cognitiva

Luis Fernando Pedraza Martínez

Universidad Nacional de Colombia
Facultad de Ingeniería
Departamento de Ingeniería de Sistemas e Industrial
Bogotá D.C, Colombia
2016

Modelo de propagación para un entorno urbano que identifica las oportunidades espectrales para redes móviles de radio cognitiva

Luis Fernando Pedraza Martínez

Tesis presentada como requisito parcial para optar al título de:

Doctor en Ingeniería - Sistemas y Computación

Directora:

Ph.D. Ingrid Patricia Páez

Línea de Investigación:

Computación aplicada - Telecomunicaciones

Universidad Nacional de Colombia

Facultad de Ingeniería

Departamento de Ingeniería de Sistemas e Industrial

Bogotá D.C, Colombia

2016

Dedicado a Dios por enseñarme su perfecto amor.

Agradecimientos

A mi directora, la profesora Ingrid Patricia Páez por su constante apoyo.

A los jurados por sus oportunas realimentaciones.

A Cesar Augusto Hernández y Danilo Alfonso López por sus asesorías.

A la Universidad Distrital y Colciencias por su apoyo.

A los profesores del Doctorado en Ingeniería de Sistemas y Computación de la Universidad Nacional de Colombia por compartirme su conocimiento y ser tan diligentes.

Finalmente, yo quiero agradecer a: Dios, mi familia consanguínea, mi familia espiritual, mi madre, mi novia y mi negrita (Q.E.P.D).

Resumen

El pronóstico de ocupación del espectro radioeléctrico es útil en el diseño de sistemas inalámbricos que aprovechan las oportunidades en el espectro como la radio cognitiva. En este documento se propone el desarrollo de un modelo de propagación, que a través del pronóstico de la potencia recibida, identifica las oportunidades espectrales en canales de una red móvil celular para un entorno urbano. El modelo propuesto integra un modelo de propagación a gran escala con un modelo neuronal wavelet, que combina las pérdidas promedio con las pérdidas instantáneas. Los resultados del modelo, obtenidos a través de simulaciones, son consistentes con el comportamiento observado en experimentos de este tipo de sistemas inalámbricos.

Palabras clave: Espectro radioeléctrico, radio cognitiva, series de tiempo, modelo de propagación, ciclo de trabajo.

Abstract

The forecast of the radioelectric spectrum occupancy is useful for wireless systems designs that take advantage of spectrum opportunities, such as cognitive radio. In this document the development of a propagation model is proposed, that through the forecasting of received power, identifies the spectral opportunities in channels of a cellular mobile network for an urban environment. The proposed model integrates a large-scale propagation model with a wavelet neural model, which combines the average losses with the instantaneous losses. The results of this model, which are obtained through simulations, are consistent with the behavior observed experimentally of this class of wireless systems.

Keywords: Radioelectric spectrum, cognitive radio, time series, propagation model, duty cycle.

Contenido

	Pág.
Resumen	V
Lista de figuras.....	IX
Lista de tablas	XIII
Lista de Símbolos y abreviaturas.....	XV
Introducción	1
Justificación.....	3
Objetivos	4
Objetivo general	4
Objetivos específicos	4
Contribución	4
1. Marco teórico.....	7
1.1 Detección de espectro	10
1.1.1 Detección de energía.....	11
1.1.2 Detección por filtro adaptado	11
1.1.3 Detección basada en características cicloestacionarias.....	12
1.2 Propagación en radio cognitiva.....	13
1.2.1 Efectos de las características de propagación	13
1.2.2 Modelos de pérdida por trayectoria.....	14
2. Análisis de modelos.....	19
2.1 Modelos de propagación en ambientes exteriores.....	19
2.1.1 Modelo de Okumura-Hata.....	19
2.1.2 Modelo COST 231 Walfisch-Ikegami	20
2.1.3 Modelo interino de la Universidad de Stanford.....	22
2.2 Modelos de series de tiempo	23
2.2.1 Análisis lineal.....	24
2.2.2 Análisis no lineal	29
3. Análisis estadístico para las mediciones de la red móvil.....	51
3.1 Metodología para medición del espectro radioeléctrico	51
3.1.1 Frecuencia.....	53

3.1.2	Localización	53
3.1.3	Amplitud	53
3.2	Análisis de bandas móviles	56
4.	Diseño del modelo de propagación	63
4.1	Análisis y validación del modelo estacional ARIMA	63
4.2	Análisis y validación del modelo GARCH	68
4.3	Análisis y validación del modelo de Markov	78
4.4	Análisis y validación del modelo EMD-SVR	84
4.5	Análisis y validación del modelo neuronal wavelet	88
4.6	Ajuste a modelos de propagación	93
4.6.1	Ajuste al modelo Okumura-Hata	95
4.6.2	Ajuste al modelo Cost 231 Walfisch-Ikegami	99
4.6.3	Ajuste al modelo interino de la Universidad de Stanford	104
4.7	Metodología de diseño del modelo de propagación	109
5.	Resultados y discusión	111
5.1	Ciclo de trabajo	118
6.	Conclusiones y recomendaciones	126
6.1	Conclusiones	126
6.2	Recomendaciones	128
	Bibliografía	129

Lista de figuras

	Pág.
Figura 1-1: Concepto de radio cognitiva [41].	8
Figura 1-2: Hueco espectral y acceso dinámico al espectro [30].	9
Figura 1-3: Ciclo Cognitivo [43].	10
Figura 1-4: Principio de la propagación multitrayecto [68].	15
Figura 1-5: Clasificación de modelos de propagación a gran escala [77].	17
Figura 2-1: Parámetros para el modelo C231-W-I [70].	21
Figura 2-2: Diagrama de flujo del modelo EMD-SVR [129].	46
Figura 2-3: Modelo de una neurona [147].	49
Figura 2-4: Red neuronal multi-capa de alimentación hacia adelante [144].	50
Figura 3-1: Configuración de la medición [149].	52
Figura 3-2: Ciclo de trabajo del rango completo de espectro medido durante la Campaña [149].	55
Figura 3-3: Porcentaje del ciclo de trabajo de acuerdo a los servicios ofrecidos en las bandas medidas [149].	55
Figura 3-4: Potencias medidas para tres canales del enlace de bajada de la banda GSM.	56
Figura 3-5: Ciclos de trabajo de tres canales del enlace de bajada de la banda GSM.	57
Figura 3-6: Distribución de oportunidades de periodos de tiempo del canal de ocupación baja.	57
Figura 3-7: Distribución de oportunidades de periodos de tiempo del canal de ocupación media.	58
Figura 3-8: Distribución de oportunidades de periodos de tiempo del canal de ocupación alta.	58
Figura 3-9: Autocorrelación para los tres canales del enlace de bajada de la banda GSM [100].	59
Figura 3-10: Estimación del parámetro de <i>Hurst</i> para el canal de ocupación baja.	60
Figura 3-11: Estimación del parámetro de <i>Hurst</i> para el canal de ocupación media.	60
Figura 3-12: Estimación del parámetro de <i>Hurst</i> para el canal de ocupación alta.	61
Figura 4-1: Componentes de tendencia y estacionalidad de los canales GSM [100].	64
Figura 4-2: Autocorrelación simple y parcial para los canales GSM [100].	64
Figura 4-3: Series de los canales GSM y series pronosticadas para el modelo SARIMA.	66
Figura 4-4: Tiempo de disponibilidad de los canales para el modelo SARIMA.	66
Figura 4-5: Tiempo de ocupación de los canales para el modelo SARIMA.	67
Figura 4-6: Error de predicción vs. Tiempo de observación para el modelo SARIMA.	68

Figura 4-7: Quinta diferencia de las potencias medidas en los canales de la banda GSM.	69
Figura 4-8: Gráficas de correlación de los canales de la banda GSM.	70
Figura 4-9: Innovaciones, desviaciones estándar condicionales y retornos de los canales GSM.	74
Figura 4-10: Autocorrelación de las innovaciones estandarizadas al cuadrado de los canales GSM.	74
Figura 4-11: Histograma de residuos y probabilidad normal para los canales GSM.	76
Figura 4-12: Series de los canales GSM y series pronosticadas con el modelo GARCH.	76
Figura 4-13: Tiempo de ocupación de los canales para el modelo GARCH.	77
Figura 4-14: Tiempo de disponibilidad de los canales para el modelo GARCH.	77
Figura 4-15: Error de Predicción vs. Tiempo de observación para el modelo GARCH.	78
Figura 4-16: Diagrama de flujo de modelo oculto de Markov.	79
Figura 4-17: Series de tiempo medida y pronosticada para los canales GSM con el modelo de Markov.	80
Figura 4-18: Evolución de los parámetros α , γ , ξ y la probabilidad de transición para los canales GSM. a) Ocupación baja, b) Ocupación media, c) Ocupación alta.	81
Figura 4-19: Tiempo de disponibilidad de canales para el modelo de Markov.	82
Figura 4-20: Tiempo de ocupación de canales para el modelo de Markov.	82
Figura 4-21: Error de predicción de vs. Tiempo de observación para el modelo de Markov.	83
Figura 4-22: Resultados de los datos EMD para el canal de ocupación baja.	84
Figura 4-23: Resultados de los datos EMD para el canal de ocupación media.	84
Figura 4-24: Resultados de los datos EMD para el canal de ocupación alta.	85
Figura 4-25: Series de tiempo medida y pronosticada de los canales GSM para el modelo EMD-SVR.	85
Figura 4-26: Tiempo de disponibilidad de canales para el modelo EMD-SVR.	86
Figura 4-27: Tiempo de ocupación de canales para el modelo EMD-SVR.	86
Figura 4-28: Error de predicción vs. Tiempo de observación para el modelo EMD-SVR.	87
Figura 4-29: Red neuronal wavelet.	88
Figura 4-30: Series de tiempo medida y pronosticada para los canales GSM con el modelo neuronal wavelet.	89
Figura 4-31: Tiempo de ocupación de canales para el modelo neuronal wavelet.	90
Figura 4-32: Tiempo de disponibilidad de canales para el modelo neuronal wavelet.	90
Figura 4-33: Error de predicción vs. Tiempo de observación para el modelo neuronal wavelet.	91
Figura 4-34: Puntos de medida en la zona norte de la ciudad de Bogotá D.C.	94
Figura 4-35: Potencia de recepción teórica y medida para el modelo O-H del canal bajo.	96
Figura 4-36: Potencia de recepción teórica y medida para el modelo O-H del canal medio.	96
Figura 4-37: Potencia de recepción teórica y medida para el modelo O-H del canal alto.	97
Figura 4-38: Potencia de recepción ajustada y medida para el modelo O-H del canal bajo.	98

Figura 4-39: Potencia de recepción ajustada y medida para el modelo O-H del canal medio.	98
Figura 4-40: Potencia de recepción ajustada y medida para el modelo O-H del canal alto.	99
Figura 4-41: Potencia de recepción teórica y medida para el modelo C231-W-I del canal bajo.	100
Figura 4-42: Potencia de recepción teórica y medida para el modelo C231-W-I del canal medio.	100
Figura 4-43: Potencia de recepción teórica y medida para el modelo C231-W-I del canal alto.	101
Figura 4-44: Potencia de recepción ajustada y medida para el modelo C231-W-I del canal bajo.	102
Figura 4-45: Potencia de recepción ajustada y medida para el modelo C231-W-I del canal medio.	103
Figura 4-46: Potencia de recepción ajustada y medida para el modelo C231-W-I del canal alto.	104
Figura 4-47: Potencia de recepción teórica y medida para el modelo SUI del canal bajo.	105
Figura 4-48: Potencia de recepción teórica y medida para el modelo SUI del canal medio.	106
Figura 4-49: Potencia de recepción teórica y medida para el modelo SUI del canal alto.	106
Figura 4-50: Potencia de recepción ajustada y medida para el modelo SUI del canal bajo.	107
Figura 4-51: Potencia de recepción ajustada y medida para el modelo SUI del canal medio.	107
Figura 4-52: Potencia de recepción ajustada y medida para el modelo SUI del canal alto.	108
Figura 4-53: Esquema del modelo de propagación propuesto.	110
Figura 5-1: Ejemplo de aplicación para el modelo de propagación diseñado.	111
Figura 5-2: Potencia de recepción para el modelo O-H del canal bajo.	112
Figura 5-3: Potencia de recepción para el modelo O-H del canal medio.	113
Figura 5-4: Potencia de recepción para el modelo O-H del canal alto.	113
Figura 5-5: Potencia de recepción para el modelo C231-W-I del canal bajo.	114
Figura 5-6: Potencia de recepción para el modelo C231-W-I del canal medio.	115
Figura 5-7: Potencia de recepción para el modelo C231-W-I del canal alto.	115
Figura 5-8: Potencia de recepción para el modelo SUI del canal bajo.	116
Figura 5-9: Potencia de recepción para el modelo SUI del canal medio.	116
Figura 5-10: Potencia de recepción para el modelo SUI del canal alto.	117
Figura 5-11: Arquitectura de CR con infraestructura.	118
Figura 5-12: Ciclo de trabajo para el modelo de O-H del canal bajo.	120
Figura 5-13: Ciclo de trabajo para el modelo de O-H del canal medio.	120
Figura 5-14: Ciclo de trabajo para el modelo de O-H del canal alto.	121
Figura 5-15: Ciclo de trabajo para el modelo de C231-W-I del canal bajo.	121

Figura 5-16: Ciclo de trabajo para el modelo de C231-W-I del canal medio.....	122
Figura 5-17: Ciclo de trabajo para el modelo de C231-W-I del canal alto.....	122
Figura 5-18: Ciclo de trabajo para el modelo de SUI del canal bajo.	123
Figura 5-19: Ciclo de trabajo para el modelo de SUI del canal medio.	123
Figura 5-20: Ciclo de trabajo para el modelo de SUI del canal alto.....	124

Lista de tablas

	Pág.
Tabla 1-1: Características de las técnicas fundamentales de detección de usuarios primarios	12
Tabla 2-1: Parámetros del modelo SUI [71].	23
Tabla 3-1: Especificaciones de los equipos de medida [149].	52
Tabla 4-1: Valores AIC para diferentes modelos.	65
Tabla 4-2: Comparación de variables de error para el modelo SARIMA.	67
Tabla 4-3: Prueba-Q Ljung-Box-Pierce de autocorrelación: (en 95% de confianza) para canales GSM.	69
Tabla 4-4: Prueba de ARCH Engle de heterocedasticidad: (en 95% de confianza) para canales GSM.	70
Tabla 4-5: Comparación de modelos GARCH para el canal bajo.	71
Tabla 4-6: Comparación de modelos GARCH para el canal medio.	71
Tabla 4-7: Comparación de modelos GARCH para el canal alto.	71
Tabla 4-8: Estimación de los parámetros para el modelo de canal bajo.	72
Tabla 4-9: Estimación de los parámetros para el modelo de canal medio.	72
Tabla 4-10: Estimación de los parámetros para el modelo de canal alto.	73
Tabla 4-11: Prueba-Q Ljung-Box-Pierce en innovaciones estandarizadas para canales GSM.	75
Tabla 4-12: Prueba de ARCH Engle en innovaciones estandarizadas para canales GSM.	75
Tabla 4-13: Comparación de variables de error para canales GSM con base en el modelo de Markov.	83
Tabla 4-14: Comparación de variables de error para canales GSM con base en el modelo EMD-SVR.	87
Tabla 4-15: Comparación de variables de error para canales GSM con base en el modelo neuronal wavelet.	91
Tabla 4-16: Resultado de error cuadrático medio para el canal bajo, con diferentes días de entrenamiento del modelo neuronal wavelet.	92
Tabla 4-17: Resultado de error cuadrático medio para el canal medio con diferentes días de entrenamiento del modelo neuronal wavelet.	92
Tabla 4-18: Resultado de error cuadrático medio para el canal alto con diferentes días de entrenamiento del modelo neuronal wavelet.	93
Tabla 4-19: Parámetros de la BTS y el analizador.	94

Tabla 4-20: Pérdidas de propagación del modelo O-H para los puntos de medida de la Figura 4-34.	95
Tabla 4-21: Error cuadrático medio del modelo O-H ajustado.	98
Tabla 4-22: Pérdidas de propagación del modelo C231-W-I para los puntos de medida de la Figura 4-34.	99
Tabla 4-23: Error cuadrático medio del modelo C231-W-I ajustado.	104
Tabla 4-24: Pérdidas de propagación del modelo SUI para los puntos de medida de la Figura 4-34.	105
Tabla 4-25: Error cuadrático medio del modelo SUI ajustado.	108
Tabla 5-1: Valores experimentales de σ_{Sk} y σ_N para GSM.	119

Lista de Símbolos y abreviaturas

Abreviaturas

Abreviatura	Término
<i>ACF</i>	Función de autocorrelación
<i>AIC</i>	Criterio de información de Akaike
<i>ANE</i>	Agencia Nacional del Espectro
<i>ANN</i>	Red neuronal artificial
<i>AR</i>	Autorregresivo
<i>ARCH</i>	Modelo de heterocedasticidad condicional autorregresiva
<i>ARIMA</i>	Modelo autorregresivo integrado de media móvil
<i>BTS</i>	Estación base
<i>C231-W-I</i>	Modelo COST231 Walfisch-Ikegami
<i>CD</i>	Retardo de coordenadas
<i>CMR</i>	Conferencias Mundiales de Radiocomunicaciones
<i>CR</i>	Radio cognitiva
<i>DARPA</i>	Agencia de Investigación de Proyectos Avanzados de Defensa
<i>DEP</i>	Densidad espectral de potencia
<i>DWT</i>	Transformada wavelet discreta
<i>EM</i>	Expectativa de maximización
<i>EMD</i>	Descomposición de modo empírico
<i>EMD-SVR</i>	Modelo de descomposición de modo empírico-vector de soporte para regresión
<i>EMV</i>	Estimación de máxima verosimilitud
F_{An}	Factor de ruido del analizador de espectro
F_{ca}	Factor de ruido del cable
<i>FCC</i>	Comisión Federal de Comunicaciones
F_{LNA}	Factor de ruido del amplificador de bajo ruido
F_T	Factor de ruido total
G_{An}	Ganancia antena analizador
<i>GARCH</i>	Modelo de heterocedasticidad condicional autorregresiva generalizada
G_{BTS}	Ganancia antena estación base
G_{ca}	Ganancia del cable
G_{LNA}	Ganancia amplificador de bajo ruido
<i>GPS</i>	Sistema de posicionamiento global
<i>GSM</i>	Sistema global para comunicaciones móviles
<i>H</i>	Parámetro de <i>Hurst</i>
<i>HMM</i>	Modelo oculto de Markov

Abreviatura Término

<i>IID</i>	Independiente e idénticamente distribuida
<i>IMF</i>	Funciones de modo intrínsecas
L_c	Pérdidas cable de la estación base
L_{ca}	Pérdidas cable analizador
L_{co}	Pérdidas combinador de la estación base
L_0	Pérdidas por espacio libre
L_{msd}	Pérdidas por difracción multipantalla
L_{rts}	Pérdidas desde el borde del último techo hasta el móvil
<i>MA</i>	Media móvil
<i>MAE</i>	Error absoluto medio
<i>MAPE</i>	Error porcentual absoluto medio
<i>NF</i>	Figura de ruido
<i>NLOS</i>	Sin línea de vista
<i>O-H</i>	Modelo Okumura-Hata
<i>OFDM</i>	Multiplexación por división de frecuencia ortogonal
<i>PACF</i>	Función de autocorrelación parcial
<i>pdf</i>	Función de densidad de probabilidad
<i>Pfa</i>	Probabilidad de falsa alarma
P_N	Potencia de ruido
P_{Rx}	Potencia de recepción
<i>PSR</i>	Reconstrucción del espacio de fase
P_{Tx}	Potencia de transmisión
<i>PU</i>	Usuario primario
<i>RBF</i>	Función de base radial
<i>RBW</i>	Ancho de banda de resolución
<i>RF</i>	Radiofrecuencia
<i>RMS</i>	Valor cuadrático medio
<i>Rx</i>	Receptor
<i>SARIMA</i>	Modelo autorregresivo integrado de media móvil estacional
<i>SFDR</i>	Margen dinámico libre de espurios
<i>SMAPE</i>	Error porcentual absoluto medio simétrico
<i>SVR</i>	Vector de soporte para regresión
<i>SUI</i>	Modelo interino de la Universidad de Stanford
<i>Tx</i>	Transmisor

Introducción

El espectro radioeléctrico se percibe como un bien escaso. En la actualidad, el uso de buena parte de las bandas licenciadas está mal distribuido; pues, normalmente, se pueden encontrar bandas de frecuencia muy congestionadas y otras bandas poco utilizadas. La radio cognitiva (CR) se ha convertido en uno de los paradigmas más investigados en las comunicaciones de radio para optimizar el uso del espectro radioeléctrico [1]. Una CR es una radio inteligente, consciente de su entorno, capaz de reconfigurarse de manera autónoma para aprender y adaptarse al entorno de radio que la rodea [2]. La investigación en CR ha sido motivada por los resultados de las campañas de medición de espectro realizadas en todo el mundo [3-13]. Estas campañas de medición muestran que el espectro radioeléctrico está subutilizado en los dominios de frecuencia, tiempo y espacio geográfico [4, 6-8, 10, 13].

En Colombia y en el mundo, las políticas para la regulación del espectro radioeléctrico, que son tradicionalmente aplicadas, conciernen, en una parte, a la asignación exclusiva de bandas del espectro a operadores de tecnologías inalámbricas y, en otra parte, a la concesión de bandas del espectro para el uso libre por parte de operadores y usuarios particulares [14]. Estas políticas de asignación espectral han permitido el desarrollo del sector de las telecomunicaciones; sin embargo, el elevado costo de las licencias para la asignación del espectro concesionado, la escasez de espectro para la asignación a nuevos operadores, el bajo porcentaje de uso que le dan, en su mayoría, los operadores al espectro licenciado [15] y los elevados niveles de interferencia en las bandas libres del espectro, han hecho que se consideren novedosas estrategias, como la CR, para contrarrestar estas deficiencias [16, 17].

El principio para el funcionamiento de la CR se basa en que los usuarios no licenciados no interfieran a los usuarios licenciados; para ello, una forma de enfrentar este problema es que los usuarios no licenciados detecten la ocupación del espectro en diferentes localizaciones, como función del entorno considerado y de las condiciones de

propagación; esto proporciona una valiosa herramienta para el diseño, dimensionamiento y evaluación del rendimiento en redes de CR [18].

Los modelos de propagación comenzaron a formularse a finales de la década de los años sesenta, con el fin de estimar con precisión las pérdidas de propagación en un entorno. Inicialmente, se diseñaron modelos de propagación empíricos y estadísticos en áreas urbanas [19, 20]; luego, con el despliegue de las comunicaciones móviles a comienzos de la década de los ochenta, se diseñaron modelos de propagación para escenarios de microceldas y macroceldas [21-23]. A partir de esto, se han desarrollado numerosos esfuerzos para entender y predecir las características de los canales en las comunicaciones móviles [24], que hace parte de esta investigación.

Las series de tiempo han sido usadas, en algunos casos, como mecanismo para el pronóstico de las pérdidas de propagación. Por ejemplo, se han utilizado las redes neuronales para pronosticar la intensidad de campo [25] y las pérdidas promedio de propagación [26, 27]. Además, se ha empleado la lógica difusa para este mismo propósito [28]. En la presente investigación las series de tiempo se usan en el pronóstico de la potencia recibida en una red móvil celular.

Por tanto, en este documento se desarrolla un pronóstico de la potencia recibida para identificar las oportunidades espectrales en una red móvil licenciada, la cual integra un modelo de propagación a gran escala, con un modelo estadístico en un entorno urbano.

El documento está organizado de la siguiente forma: en el Capítulo 1, se realiza una breve presentación del concepto de CR, de las técnicas de detección de espectro y de la afectación de la propagación en la CR. En el Capítulo 2, se realiza una descripción de los modelos de propagación, y de las series de tiempo utilizados y evaluados en la presente investigación. En el Capítulo 3, se expone el procedimiento de medición del espectro. En el Capítulo 4, se realiza un análisis y validación de los modelos de series de tiempo, así como el ajuste a los modelos de propagación en función de las medidas; a su vez, se presenta la metodología para el diseño del modelo de propagación propuesto. En el Capítulo 5, se exponen los resultados de la potencia recibida y el ciclo de trabajo para los nuevos modelos diseñados. Finalmente, en el Capítulo 6, se exhiben las conclusiones y recomendaciones del presente trabajo.

Justificación

La creciente necesidad de comunicarse cada vez más, a través de tecnologías inalámbricas, trae consigo el aumento en la ocupación del espectro radioeléctrico y, por consiguiente, la interferencia entre diferentes equipos, especialmente, los usados en las bandas no licenciadas. Esto puede causar pérdidas de información, errores de transmisión, entre otros problemas. Por tanto, se han desarrollado diferentes técnicas para minimizar las interferencias como: el *beamforming*, el espectro ensanchado, el salto en frecuencia y el control de potencia adaptativo, entre otros [29].

Asimismo, es importante el estudio de tecnologías que permitan el uso más eficiente del espectro radioeléctrico, como lo es la CR, donde es necesario detectar los espacios del espectro que no están siendo usados por parte de los usuarios licenciados, de modo que se pueda conllevar a una asignación oportunista y dinámica de este espectro restante, a usuarios no licenciados que lo soliciten [30].

La CR es un tema que se encuentra, desde la pasada década, en investigación teórica [31], los fabricantes de telefonía celular como Nokia [32] y departamentos como la Agencia de Investigación de Proyectos Avanzados de Defensa (DARPA) [33], entre otros, se encuentran financiando este tema de investigación en aras de lograr la implementación física de estas redes. En Colombia, esta temática es liderada por entidades como la Agencia Nacional del Espectro (ANE), con el fin de definir políticas de espectro en el país y hacer aportes a nivel regulatorio en las Conferencias Mundiales de Radiocomunicaciones (CMR). Esto hace necesario una continua investigación en esta área, en campos como la propagación [34-36]; una investigación que conlleve al despliegue de esta tecnología emergente y se logren superar, de una manera eficiente, los inminentes problemas frente a la subutilización e inadecuada distribución del espectro radioeléctrico, lo que no solo beneficiará a los operadores de redes inalámbricas, sino a los usuarios de estas tecnologías, puesto que podrán poseer más servicios, lo que redundará en más operadores y más competencia, y, por tanto, menos costo [37].

Por esta razón, esta tesis consiste en el desarrollo de un modelo de propagación que identifica las oportunidades espectrales en una red móvil a partir de mediciones realizadas en un entorno urbano.

Objetivos

Objetivo general

Desarrollar un modelo de propagación para un entorno urbano capaz de identificar oportunidades espectrales para redes móviles de radio cognitiva.

Objetivos específicos

- Analizar estadísticamente las tendencias de ocupación espectral con base en mediciones realizadas, en redes móviles para un entorno urbano.
- Diseñar un modelo de simulación que integre características de propagación a gran escala con el análisis estadístico.
- Evaluar los resultados del modelo de propagación en un entorno urbano controlado¹ utilizando las variables tiempo, distancia y potencia.

Contribución

La principal contribución de este trabajo consiste en la propuesta de un modelo de propagación, el cual integra las pérdidas promedio con las pérdidas instantáneas para pronosticar la potencia recibida en un usuario no licenciado proveniente de un transmisor licenciado en un entorno urbano.

Para lograr este propósito, se toman medidas del espectro radioeléctrico, emitidas por un transmisor licenciado, durante una semana en un entorno urbano. A continuación, se seleccionan tres canales con diferentes niveles de ocupación de la tecnología: 'sistema global para comunicaciones móviles (GSM)'. Con esta información de la potencia medida, se validan y evalúan los modelos de series de tiempo: SARIMA, GARCH, Markov, EMD-SVR y neuronal wavelet; seguidamente, con estas medidas y las características del entorno urbano, se ajustan los modelos de propagación a gran escala que más se adecuan. Posteriormente, se entrena el modelo de serie de tiempo seleccionado, con los datos medidos, y se integra con el modelo a gran escala, a fin de

¹ Entorno urbano controlado: Es aquel en el que se conocen las características técnicas y la ubicación de las estaciones transmisoras.

pronosticar la potencia que se recibiría desde el transmisor licenciado a lo largo del entorno. Finalmente, se exhibe el ciclo de trabajo, el cual determina la ocupación espectral a lo largo del entorno.

Este tipo de modelos son muy útiles en las comunicaciones inalámbricas, puesto que contribuye en el compartir del espectro radioeléctrico, entre usuarios licenciados y no licenciados en una red de CR.

1.Marco teórico

Para abordar los problemas de limitación de espectro, la Comisión Federal de Comunicaciones (FCC) aprobó el uso de dispositivos no licenciados en las bandas licenciadas [38]. En consecuencia, se proponen las técnicas de acceso dinámico al espectro para resolver los problemas actuales de ineficiencia espectral [2].

La tecnología clave para el acceso dinámico al espectro es la CR, que está emergiendo como una tecnología promisorio e innovadora, que tiene como fin, solventar y solucionar uno de los grandes problemas de los sistemas de comunicaciones inalámbricas de próxima generación: la escasez de espectro radioeléctrico y la subutilización del mismo. Esta tecnología provee la capacidad de compartir, de una manera oportunista, el canal inalámbrico con los usuarios que poseen una parte licenciada del espectro [30, 39].

El término CR, formalmente, se puede definir de la siguiente forma [40]:

Una CR es una radio que puede cambiar los parámetros del transmisor basado en la interacción con el entorno en que este opera.

A partir de esta definición, dos características principales de la CR pueden ser definidas de la siguiente manera [41]:

- **Capacidad Cognitiva:** la capacidad cognitiva se refiere a la habilidad de la tecnología de radio para capturar o detectar la información y adaptarse a su entorno de radio. Esta capacidad no solo puede ser realizada mediante la monitorización de potencia en una banda de frecuencias de interés, sino que las técnicas más sofisticadas, tales como el aprendizaje autónomo y la decisión de acción son requeridas para captar las variaciones temporales y espaciales en el entorno de radio, y, así, evitar la interferencia a otros usuarios.

- **Reconfigurabilidad:** la CR puede ser programada para transmitir y recibir señales en una variedad de frecuencias, y para usar diferentes tecnologías de acceso de transmisión, con el apoyo de su hardware [42].

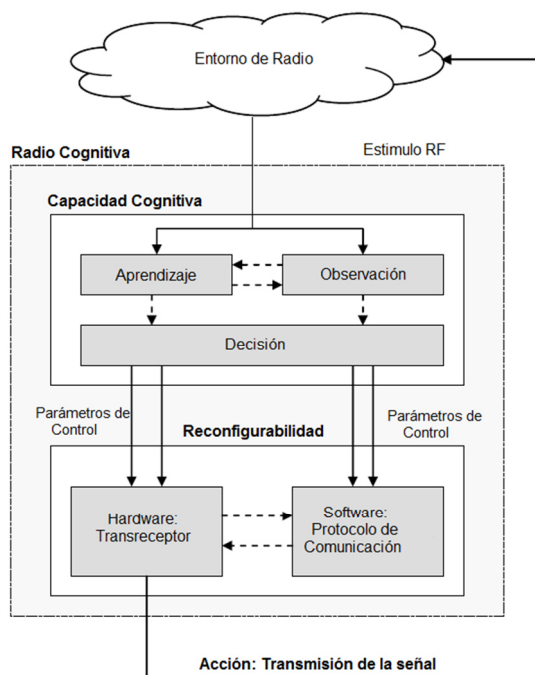


Figura 1-1: Concepto de radio cognitiva [41].

En la Figura 1-1, se muestra el concepto de CR a través de la capacidad cognitiva y la reconfiguración. En primer lugar, la CR identifica la información de radio a través de la observación y los procesos de aprendizaje y, por consiguiente, toma las decisiones apropiadas.

Basada en estas decisiones, la CR reconfigura su software (p. e. los protocolos de comunicación) y el hardware (p. e., una frecuencia de radio para el *RF front-end* y una antena).




Figura 1-2: Hueco espectral y acceso dinámico al espectro [30].

A través de la capacidad cognitiva y la reconfigurabilidad, la CR permite el uso del espectro no utilizado temporalmente, lo que se conoce como un *hueco espectral* o *espacio en blanco* [1]. Si esta banda es usada por un usuario licenciado, también llamado usuario primario (PU), la CR se mueve a otro *hueco espectral* para evitar interferir a los PU, como se muestra en la Figura 1-2. Esta nueva área de investigación prevé el desarrollo de las redes de CR a fin de mejorar la eficiencia espectral.

La CR ofrece la capacidad de compartir los canales inalámbricos con los PU de una manera oportunista. Con este fin, los usuarios de CR (usuarios no licenciados o usuarios secundarios) necesitan monitorear continuamente el espectro para determinar la presencia de los PU y reconfigurar el *RF front-end* de acuerdo con las demandas y necesidades de las capas superiores.

Para cumplir con lo anterior, las redes de CR necesitan conocer las operaciones del espectro, que forman un ciclo cognitivo. Como se muestra en la Figura 1-3, el ciclo cognitivo consta de cuatro funciones para gestionar el espectro: detección de espectro, decisión de espectro, compartir el espectro y movilidad de espectro. Para implementar redes de CR, cada función necesita ser incorporada en los protocolos clásicos de capas. Las siguientes son las principales características de las funciones para gestionar el espectro [30]:

1. **Detección de espectro:** un usuario de CR supervisa las bandas disponibles del espectro, captura su información y, después, detecta los huecos del espectro.
2. **Decisión de espectro:** basados en la disponibilidad del espectro, los usuarios de CR pueden determinar la mejor banda espectral. Esta operación no solo depende de

la disponibilidad de espectro, sino también se determina basándose en políticas internas (y posiblemente externas).

3. **Compartir el espectro:** desde que múltiples usuarios de CR intentan acceder al espectro, el acceso a la red de CR se debe coordinar para prevenir que los múltiples usuarios colisionen en las partes solapadas del espectro.
4. **Movilidad de espectro:** Los usuarios de CR son considerados como “visitantes” en el espectro. Si los PU necesitan una parte específica del espectro o si las condiciones del canal se deterioran, los usuarios de CR deben continuar en otra parte vacante del espectro.

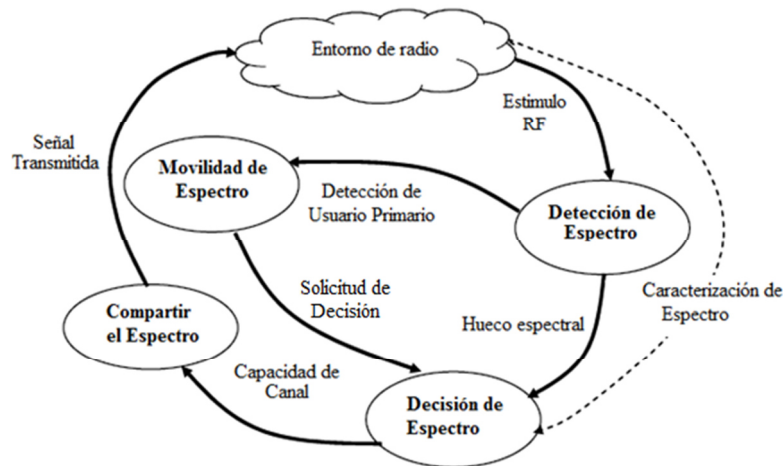


Figura 1-3: Ciclo Cognitivo [43].

1.1 Detección de espectro

La detección de espectro ha sido brevemente definida como: la labor de obtener espectro disponible, determinando la existencia de PU dentro de una región geográfica definida. Esto se obtiene de diversas formas dentro de las cuales se encuentra la detección local del espectro en CR [44-46]. En la técnica de acceso al espectro *overlay*, un usuario de CR puede transmitir únicamente en frecuencias que no estén siendo usadas en el espectro que lo rodea [1].

A pesar de que la detección de espectro es, tradicionalmente, entendida como la medida de la energía de las frecuencias de radio a lo largo del espectro; cuando se trata de CR, la detección se convierte en un término más amplio, el cual involucra la obtención de características de uso espectral en múltiples dimensiones como: el tiempo, el espacio, la frecuencia y el código [47]. La detección comprende una gran variedad de aspectos

asociados con la determinación del tipo de señal que ocupa una banda; empero, esto requiere técnicas más robustas para el análisis de señales, las cuales suponen mayor complejidad desde el punto de vista computacional [48].

A continuación se presentan de forma general las técnicas fundamentales de detección de espectro; las cuales, a su vez, son la base para desarrollar algoritmos de detección más elaborados [48-54]:

1.1.1 Detección de energía

La detección de energía en las bandas de frecuencia es la forma más común de detectar oportunidades en el espectro (p.e., en los analizadores de espectro), debido a su bajo nivel de complejidad, en términos de computación e implementación, al compararse con otras técnicas [55-60]. De acuerdo con esta técnica, se determinará que existe un usuario licenciado transmitiendo en una banda determinada, cuando el promedio de las muestras detectadas en una banda del espectro en particular supera un umbral específico.

Las señales son detectadas comparando el nivel de salida de un detector de energía con respecto a un umbral que depende del ruido [61, 62]. No obstante, la selección de este umbral es una de las debilidades de esta técnica, puesto que la potencia de ruido es cambiante.

1.1.2 Detección por filtro adaptado

Básicamente, un filtro adaptado adecua su respuesta al impulso de manera tal que, al tomar las muestras de la señal en un tiempo específico, la salida del filtro sea equivalente a la salida de un receptor de correlación. Esta técnica es reconocida por su óptimo desempeño en la detección de usuarios licenciados, cuando las señales transmitidas son conocidas [49], esto es equivalente a la convolución de la señal desconocida, con una versión de tiempo de la señal conocida. La complejidad de implementar este tipo de detección es muy alta para ser llevada a la práctica [56].

1.1.3 Detección basada en características cicloestacionarias

En este caso, para detectar la presencia de usuarios licenciados, se explota la naturaleza periódica de las señales moduladas, es decir que, a diferencia de lo que sucede en la detección de energía, una señal que porte información será muy diferente del ruido y de la interferencia debido a los cambios consecutivos que se presentan en periodos iguales de tiempo (p.e., la tasa a la que cambian los símbolos o la periodicidad intrínseca de las mismas portadoras)[63].

En la Tabla 1-1 se presenta una comparación de las técnicas más relevantes en la detección de usuarios primarios.

Tabla 1-1: Características de las técnicas fundamentales de detección de usuarios primarios.

Técnica de detección	Complejidad	Grado de certeza en la detección	Dimensiones espectrales involucradas	Duración de la detección	Consumo de potencia	Principal inconveniente
Energía	Baja	Bajo	Tiempo/Frecuencia/Espacio	Corta	Bajo	Selección del umbral de decisión
Filtro Adaptado	Muy alta	Muy Alto	Tiempo/Frecuencia/Espacio	Corta	Alto	Se deben conocer las características de las señales detectadas
Características cicloestacionarias	Media	Moderada/baja	Tiempo/Frecuencia/Espacio	Moderada	Alto	Alto procesamiento de la señal

En la Tabla 1-1, se observa la existencia de algunas técnicas, teóricamente robustas, para la detección del espectro; sin embargo, a nivel práctico, en estaciones de monitorización y recientes investigaciones para la medición del espectro, se hace uso de analizadores de espectro, los cuales presentan la ocupación de las bandas del espectro a través de un espectrograma; además, usan la técnica de detección de energía [4, 64, 65]. En el desarrollo de esta tesis se utilizó el analizador de espectro marca Anritsu

MS2721B, que proporciona medidas rápidas y precisas [66], para medir datos y, posteriormente, compararlos con el modelo desarrollado.

1.2 Propagación en radio cognitiva

El principio clave de la jerarquía de CR es que los usuarios de CR no interfieran a los PU; para esto, es esencial la capacidad de un usuario de CR para detectar la señal de un PU. Por esta razón, es necesario analizar la capacidad de detección de un usuario de CR para diversas condiciones de propagación [67].

1.2.1 Efectos de las características de propagación

El nivel de señal en un sensor o receptor del sistema de CR está determinado por las pérdidas por trayectoria del enlace entre este sensor y el transmisor primario, así como por el desvanecimiento a gran escala y pequeña escala de este enlace. El nivel de señal, a su vez, influye en la probabilidad de detección de una falsa alarma (espectro que es declarado ocupado a pesar de que esta libre) y la probabilidad de detección errónea (espectro que es declarado vacío a pesar de que está ocupado por un PU) [34].

Cuando la detección es usada en una banda ancha, los niveles de señal son diferentes en diversas frecuencias, debido a la selectividad de frecuencia del desvanecimiento a pequeña escala, así como, posiblemente, por la dependencia de la frecuencia en las pérdidas por trayectoria [68].

La propagación también es clave en el problema del “nodo oculto”, en donde un transreceptor secundario “no escucha” a un transmisor primario, pero está lo suficientemente cerca para crear interferencias en el receptor primario. La probabilidad de que existan nodos ocultos se incrementa con el aumento de la pérdida por trayectoria y el efecto de sombreado [68].

Encontrar las oportunidades espectrales, requiere, por parte del sistema secundario, el conocimiento preciso del canal de propagación, desde el receptor (Rx) primario hacia el transmisor (Tx) primario y el Tx secundario, en el momento de la transmisión. Con el fin de desarrollar estrategias adecuadas de transmisión, es vital que el Tx secundario sea

capaz de hacer predicciones del canal (con base en observaciones pasadas y presentes) y entender la precisión alcanzada con estas predicciones. Esto, a su vez, requiere buenos modelos de canal [69].

Las características del canal también tienen un impacto en el diseño de la estrategia de transmisión para CR. Por ejemplo, el espaciamiento óptimo de las subportadoras, en la multiplexación por división de frecuencia ortogonal (OFDM), depende del perfil de retardo de potencia y el espectro *Doppler* [70]. Por tanto, una CR debe ajustar la separación de subportadoras para el canal de propagación. El número de símbolos de la modulación debe adaptarse al nivel de la señal (este nivel de la señal depende de la pérdida por trayectoria, el sombreado y el desvanecimiento a pequeña escala). De manera general, se puede inferir que los parámetros de operación en una CR dependen, de alguna forma, del canal de propagación [68].

1.2.2 Modelos de pérdida por trayectoria

El aspecto más importante para la caracterización de la propagación de radio es la forma en la que la intensidad de la señal varía en función de la distancia y la ubicación. Esta propiedad está implícita en la pérdida por trayectoria. La pérdida por trayectoria es un mecanismo fundamental, que asegura que un Tx de CR no perturbe a un Rx primario si está lo suficientemente lejos [70].

Hay muchos modelos de pérdidas por trayectoria publicados; estos corresponden a diferentes bandas de frecuencia y entornos en los que pueden operar los radios cognitivos [19, 21, 71-74]. En varios textos [70, 75-77], se han descrito diversos mecanismos que permiten analizar la atenuación de la señal. Al mismo tiempo, se han realizado amplias mediciones del espectro, las cuales permiten modelar las pérdidas por trayectoria en bandas específicas de frecuencia y entornos (véase: [19, 21, 78-80]).




Figura 1-4: Principio de la propagación multitrayecto [68].

Normalmente, las trayectorias de radio en los sistemas inalámbricos no reúnen las condiciones de un entorno de espacio libre. A menudo no existe línea de vista y las trayectorias sin línea de vista (NLOS) son numerosas debido a múltiples obstáculos, reflexiones y dispersiones que afectan la señal recibida, como se observa en la Figura 1-4. A continuación se presenta una ecuación general de la potencia recibida por caminos inalámbricos NLOS [77]:

$$P_{Rx} = P_{Tx} \left[\alpha \left(\frac{d}{d_0} \right)^{-\gamma} \zeta s \right] \quad (1.1)$$

Donde P_{Rx} y P_{Tx} son las potencias de recepción y transmisión, respectivamente; α es una constante que puede depender de la frecuencia, la altura de la antena y otros factores; d y d_0 son la longitud del camino y una distancia de referencia, respectivamente; γ es el llamado exponente de pérdida multitrayecto, ζ y s representan los desvanecimientos a “pequeña escala” (correspondientes a los modelos de propagación a pequeña escala) y “gran escala” (correspondientes a los modelos de propagación a gran escala), respectivamente.

Los desvanecimientos a pequeña escala y gran escala también juegan un papel importante en el diseño de radios de CR debido a la introducción de aleatoriedad en la potencia de recepción. Si el desvanecimiento no existe, entonces una CR simplemente podría calcular la potencia recibida en los Rx primarios y secundarios desde las

ubicaciones geográficas de los transreceptores (esta, a su vez, se podría derivar de la potencia recibida en los nodos conocidos o receptores GPS, o por otros medios). Debido a los desvanecimientos a pequeña escala y gran escala, el conocimiento de la distancia al Tx no permite establecer una única conclusión acerca de la potencia (útil o interferencia) de recepción. La magnitud en las variaciones de la potencia es un factor importante en el cálculo de la probabilidad de interferencia [68].

Las escalas espaciales y temporales sobre las que se producen variaciones tienen un impacto en: cómo un canal tiene que ser detectado, a qué distancia deben estar ubicados los nodos de detección de manera que el desvanecimiento en estos se puede considerar sin correlación, y qué tan probable es la existencia de un nodo oculto. Por ejemplo, un Rx de CR podría detectar que un canal está disponible debido a un desvanecimiento a pequeña escala, que conlleva a una fuerte atenuación de un transreceptor primario. Si la CR transmite un poco más tarde, cuando la atenuación ha cambiado debido al desvanecimiento a pequeña escala, la radiación emitida por la CR dará lugar a una alta interferencia [70].

En diferentes investigaciones se han discutido los efectos de los fenómenos de propagación en la CR [68]. Es así como [81-83], demuestran que la ganancia de las antenas, el ancho del haz y las pérdidas por trayectoria, afectan la oportunidad espacial de reusar frecuencias para los usuarios de CR.

En [84], se analiza la interferencia que se genera en una red de CR, teniendo en cuenta la sensibilidad, la potencia de transmisión y la densidad de los radios cognitivos bajo un entorno de propagación. Para esto, se hace uso de un detector de energía con ruido gaussiano blanco y, en [85], se analiza la probabilidad de detección si el ruido no es gaussiano. En [86] se analiza la capacidad de un canal de CR para diferentes entornos de desvanecimiento, teniendo en cuenta el desvanecimiento por sombreado, así como el desvanecimiento rápido Rayleigh y Ricean. En [87, 88] se construyen modelos de propagación para interiores-exteriores, con el fin de evitar interferencias entre PU al exterior de una edificación y usuarios de CR al interior de esta.

▪ Modelos de propagación a gran escala

En la Figura 1-5, se presenta una clasificación de los modelos de propagación a gran escala. Estos son útiles para predecir la potencia promedio para una distancia de separación arbitraria entre un transmisor-receptor [77].

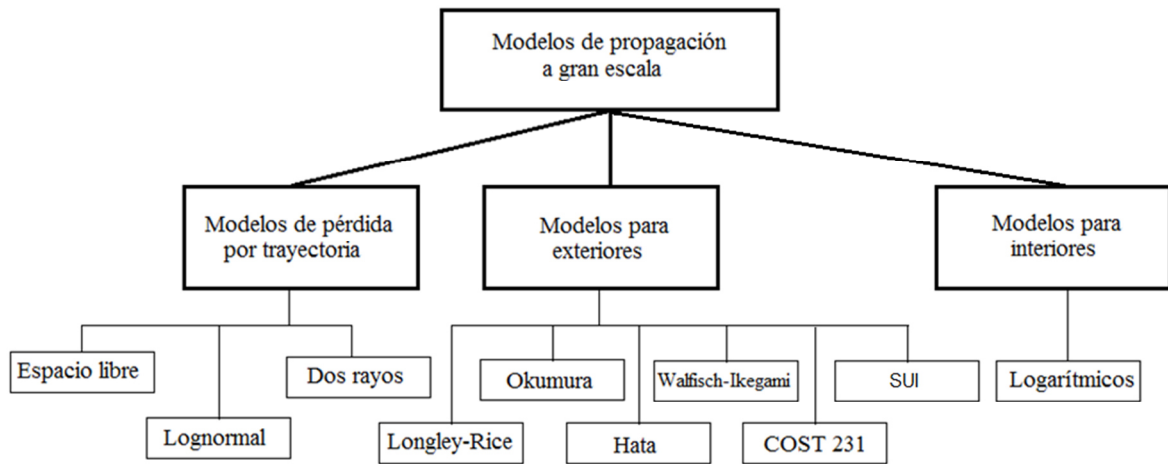


Figura 1-5: Clasificación de modelos de propagación a gran escala [77].

2. Análisis de modelos

En este Capítulo se presentan los modelos de propagación y los modelos de series de tiempo en los que se basa la presente investigación.

2.1 Modelos de propagación en ambientes exteriores

Los modelos de propagación para exteriores que se describen fueron seleccionados teniendo en cuenta que las variables que emplean se adecuan al entorno urbano analizado. Dicho entorno se estudia en el Capítulo 4.

2.1.1 Modelo de Okumura-Hata

El modelo de Okumura es uno de los más utilizados para predecir la potencia de recepción en áreas urbanas. Este modelo es aplicable para frecuencias en el rango de 150MHz a 1920MHz [19]; no obstante, Hata [21] adecuó este modelo para facilitar su aplicabilidad. La fórmula estándar de este modelo es [70]:

$$\begin{aligned}\bar{L}(dB) = & 69.55 + 26.16 \log f_c - 13.82 \log h_{te} - a(h_{re}) \\ & + (44.9 - 6.55 \log h_{te}) \log d\end{aligned}\quad (2.1)$$

Donde, \bar{L} corresponde a las pérdidas del modelo en dB, f_c es la frecuencia portadora en MHz, h_{te} es la altura de la antena transmisora en m, h_{re} es la altura de la antena receptora en m, $a(h_{re})$ es el factor de corrección para la altura efectiva de la antena móvil, que es función del tipo de área de servicio, y d es la distancia entre Tx y Rx en km. Los rangos de funcionamiento para estas variables son:

$$150 \text{ MHz} < f_c < 1500 \text{ MHz}$$

$$20 \text{ m} < h_{te} < 200 \text{ m}$$

$$1 \text{ m} < h_{re} < 10 \text{ m}$$

$$1 \text{ km} < d < 20 \text{ km}$$

El factor de corrección depende de la altura del móvil y se calcula de la siguiente forma, esto aplica para ciudades pequeñas o medianas:

$$a(h_{re}) = (1.1 \log f_c - 0.7)h_{re} - (1.56 \log f_c - 0.8) \quad (2.2)$$

Para ciudades grandes es:

$$a(h_{re}) = \begin{cases} 8.29 (\log 1.54 h_{re})^2 - 1.1 f \leq 200 \text{ MHz} \\ 3.2 (\log 11.75 h_{re})^2 - 4.97 f \geq 400 \text{ MHz} \end{cases} \quad (2.3)$$

2.1.2 Modelo COST 231 Walfisch-Ikegami

El modelo COST 231 fue creado para extender el uso del modelo Okumura-Hata (O-H) hasta los 2GHz [89]. El modelo Walfisch-Bertoni [22], el cual tiene en cuenta características de las edificaciones del entorno, fue combinado con el modelo Ikegami [90] con el propósito de considerar la difracción descendente hasta el nivel de las calles y algunos factores empíricos de corrección, los cuales dan como resultado el modelo COST 231 Walfisch-Ikegami (C231-W-I) [23]. Este es un modelo para sistemas celulares de corto alcance, en un rango de frecuencias desde 800 hasta 2000 MHz.

Este distingue entre las situaciones en las que hay línea de vista (LOS) y en las NLOS. En el caso de LOS, las pérdidas están dadas por:

$$\bar{L}(dB) = 42.6 + 26 \log d + 20 \log f_c \quad (2.4)$$

Para $d \geq 20 \text{ m}$, d esta expresada en km y f_c en MHz.

En condiciones NLOS el total de pérdidas está dado por [23]:

$$\bar{L} = L_0 + L_{rts} + L_{msd} \quad (2.5)$$

Donde L_0 son las pérdidas por espacio libre, L_{msd} son las pérdidas por difracción multipantalla a través de la trayectoria de propagación, y L_{rts} son las pérdidas desde el borde del último techo hasta el móvil. El modelo se representa en la Figura 2-1.




Figura 2-1: Parámetros para el modelo C231-W-I [70].

Los parámetros definidos en el modelo de la Figura 2-1 son los siguientes:

- h_{Roof} es la altura media de los edificios en m.
- w es el ancho de la calle en m.
- b es la separación media entre edificios en m.
- h_b es la altura de la antena de la estación base en m.
- h_m es la altura de la antena del dispositivo móvil en m.
- $\Delta h_m = h_{Roof} - h_m$, en m.
- $\Delta h_b = h_b - h_{Roof}$, en m.
- d es la distancia entre la estación base y el dispositivo móvil en km.

\bar{L} dará un valor mínimo de L_0 cuando $L_{rts} + L_{msd} \leq 0$ y, en otros casos, puede llegar a ser negativo. Las pérdidas por espacio libre están dadas por:

$$L_0(dB) = 32.4 + 20 \log d + 20 \log f_c \quad (2.6)$$

Para d expresada en km y f_c expresada en MHz.

El término L_{rts} tiene en cuenta el ancho de la calle y su orientación con respecto a la dirección de propagación de la señal. Su definición está basada en los principios de difracción del modelo de Ikegami [90]. Por tanto, L_{rts} esta dada por:

$$L_{rts} = -16.9 - 10 \log w + 10 \log f_c + 20 \log \Delta h_m + L_{ori} \quad (2.7)$$

Donde,

$$L_{ori} = \begin{cases} -10 + 0.354\varphi & \text{para } 0^\circ \leq \varphi < 35^\circ \\ 2.5 + 0.075(\varphi - 35) & \text{para } 35^\circ \leq \varphi < 55^\circ \\ 4 - 0.114(\varphi - 55) & \text{para } 55^\circ \leq \varphi \leq 90^\circ \end{cases} \quad (2.8)$$

Aquí, φ es el ángulo entre la orientación de la calle y la dirección de propagación en

grados. L_{ori} es un factor de corrección empírica que tiene en cuenta las pérdidas debido a la orientación de la calle. Para el cálculo de la pérdida por difracción multipantalla L_{msd} , los bordes de los edificios se modelan como pantallas. Por tanto,

$$L_{msd} = L_{bsh} + K_a + K_d \log d + K_f \log f_c - 9 \log b \quad (2.9)$$

Donde,

$$L_{bsh} = \begin{cases} -18 \log(1 + \Delta h_b) & \text{para } h_b > h_{Roof} \\ 0 & \text{para } h_b \leq h_{Roof} \end{cases} \quad (2.10)$$

$$K_a = \begin{cases} 54 & \text{para } h_b > h_{Roof} \\ 54 - 0.8 \Delta h_b & \text{para } h_b \leq h_{Roof} \text{ y } d \geq 0.5 \text{ km} \\ 54 - 0.8 \Delta h_b \frac{d}{0.5} & \text{para } h_b \leq h_{Roof} \text{ y } d < 0.5 \text{ km} \end{cases} \quad (2.11)$$

La dependencia de las pérdidas de propagación, con respecto a la frecuencia y la distancia, se da a través de los coeficientes K_d y K_f en la ecuación (2.9):

$$K_d = \begin{cases} 18 & \text{para } h_b > h_{Roof} \\ 18 - 15 \frac{\Delta h_b}{h_{Roof}} & \text{para } h_b \leq h_{Roof} \end{cases} \quad (2.12)$$

$$K_f = \begin{cases} -4 + 0.7 \left(\frac{f_c}{925} - 1 \right) & \text{para ciudades de tamaño medio} \\ -4 + 1.5 \left(\frac{f_c}{925} - 1 \right) & \text{para zonas metropolitanas} \end{cases} \quad (2.13)$$

2.1.3 Modelo interino de la Universidad de Stanford

El modelo interino de la Universidad de Stanford (SUI) es un modelo empírico que requiere la caracterización de cada zona de la ciudad, de acuerdo con un tipo de terreno [71]. Se definen tres tipos de terreno:

- **Tipo A:** Asociado a la mayor cantidad de pérdidas, adecuado para terreno montañoso o con colinas, y con moderada o abundante presencia de vegetación.
- **Tipo B:** Puede tratarse de terreno llano con bastantes árboles o terreno montañoso con poca vegetación.

- **Tipo C:** Asociado a pérdidas bajas, apropiado para terreno llano con poca vegetación.

Esta es la expresión matemática básica para hallar las pérdidas del modelo [71]:

$$\bar{L}(dB) = A + 10 \gamma \log \left[\frac{d}{d_0} \right] + S \quad (2.14)$$

Donde,

$$A = 20 \log \left[\frac{4\pi d_0}{\lambda} \right] \quad (2.15)$$

$$\gamma = a - b h_b + \frac{c}{h_b} \quad (2.16)$$

Acá, d es la distancia entre Tx y Rx en metros, $d_0 = 100$ m, h_b es la altura de la estación base (BTS) en metros, λ es la longitud de onda en metros, S es el efecto de sombreado, y γ es el exponente de pérdidas por trayectoria. Las constantes a , b y c dependen de la categoría del terreno y se calculan con ayuda de la Tabla 2-1.

Tabla 2-1: Parámetros del modelo SUI [71].

Parámetro	Terreno A	Terreno B	Terreno C
a	4.6	4.0	3.6
b	0.0075	0.0065	0.005
c	12.6	17.1	20
S	10.6	9.6	8.2

2.2 Modelos de series de tiempo

A continuación se describen los modelos para pronosticar el comportamiento de las señales medidas, a partir de un análisis del estado del arte para la predicción del espectro en redes de CR [91]. Para esto, se clasifican los modelos en dos según el análisis de la serie de tiempo: Análisis lineal, entre los que se usa el modelo autorregresivo integrado de media móvil estacional (SARIMA), y el modelo de heterocedasticidad condicional autorregresiva generalizada (GARCH); y el análisis no

lineal, basado en el estudio de los modelos de Markov, descomposición de modo empírico-vector de soporte para regresión (EMD-SVR) y neuronal wavelet.

2.2.1 Análisis lineal

El supuesto para este tipo de modelos consiste en considerar que la serie de tiempo es lineal y tiene una distribución estadística conocida, lo que se cumple parcialmente, como se presenta en el Capítulo 3, durante el análisis a largo plazo de la serie de tiempo medida.

▪ Modelo autorregresivo integrado de media móvil estacional

Distintos estudios han demostrado que el modelo SARIMA es adecuado para analizar series de tiempo con estacionalidad [92-94]. En los sistemas cognitivos, SARIMA se ha utilizado para modelar el ciclo de trabajo de un canal GSM [95]. Igualmente, en [96, 97] el ciclo de trabajo fue pronosticado usando el modelo autorregresivo con transformaciones *logit*, mientras que para la investigación de la presente tesis se usa SARIMA para modelar la potencia recibida en tres canales GSM, con diferentes niveles de ocupación.

En general, si una serie de tiempo exhibe una potencial estacionalidad indicada por s , entonces es ventajoso utilizar un modelo ARIMA estacional $(p, d, q)(P, D, Q)_s$, donde d es el nivel de diferenciación no estacional, p es el orden autorregresivo (AR) no estacional, q es el orden de la media móvil (MA) no estacional, P es el número de términos autorregresivos estacionales, D es el número de diferencias estacionales, y Q es el número de términos de media móvil estacional. El modelo de media móvil integrado autorregresivo estacional de Box-Jenkins [98] está dado por,

$$\phi_p(B)\Phi_p(B^s)\nabla^d\nabla_s^D x_t = \theta_q(B)\Theta_q(B^s)e_t \quad (2.17)$$

Donde B es el operador de desplazamiento hacia atrás, x_t es la serie de tiempo observada de la carga en el tiempo t , y e_t es el error distribuido normalmente, idéntico e independiente (shock aleatorio) en el período t ; $\nabla_s^D x_t = (1 - B^s)^D x_t$, $\phi_p(B^s)$ y $\Theta_q(B^s)$ son los operadores $AR(p)$ y $MA(q)$ estacionales, respectivamente, los cuales se definen como,

$$\Phi_p(B^s) = 1 - \Phi_1 B^s - \Phi_2 B^{2s} - \dots - \Phi_p B^{Ps} \quad (2.18)$$

$$\Theta_Q(B^s) = 1 - \Theta_1 B^s - \Theta_2 B^{2s} - \dots - \Theta_Q B^{Qs} \quad (2.19)$$

Donde $\phi_1, \phi_2, \dots, \phi_p$ son los parámetros del modelo AR(p) estacional, $\Theta_1, \Theta_2, \dots, \Theta_Q$ son los parámetros de la MA(q) estacional [94].

La metodología de Box-Jenkins [98] se aplica al modelo ARIMA para encontrar el mejor ajuste de una serie de tiempo a sus valores anteriores, con el fin de hacer previsiones. La metodología de Box-Jenkins consta de cuatro pasos iterativos [99]:

- **Paso 1: Identificación**

Este paso se enfoca en la selección de d, D, p, P, q y Q . El número de orden se puede identificar mediante la observación de las muestras de la función de autocorrelación (ACF) y de la función de autocorrelación parcial (PACF).

- **Paso 2: Estimación**

Los datos históricos se utilizan para estimar los parámetros del modelo tentativo del Paso 1.

- **Paso 3: Diagnóstico de verificación**

La prueba de diagnóstico se utiliza para comprobar la idoneidad del modelo tentativo.

- **Paso 4: Pronóstico**

El modelo final del Paso 3 se utiliza para pronosticar los valores [100].

- **Modelo de heterocedasticidad condicional autorregresiva generalizada**

GARCH ha sido usado para modelar el ruido aditivo en un método de detección de espectro de banda ancha para redes de radio cognitiva [101]; también se ha aplicado ampliamente en el modelamiento y pronóstico del tráfico para diferentes redes de comunicación [102-105]. Varios modelos han sido sugeridos para la captura de las características especiales de datos, y la mayoría de estos modelos tienen la propiedad de que la varianza condicional depende del pasado.

Los modelos utilizados para estos casos son: heterocedasticidad condicional autorregresiva (ARCH), introducido en [106], y el ARCH generalizada (GARCH) dado por

[107]. El modelado ARCH-GARCH considera la varianza del error condicional como una función de la comprensión del pasado de la serie.

▪ Modelo ARCH(q)

Si ε_t es el ruido blanco gaussiano con media igual a cero, la varianza es igual a la unidad, y H_t es la información establecida en el tiempo t dada por $H_t = \{r_1, r_2, \dots, r_{t-1}\}$. Entonces, el proceso $\{r_t\}$ es ARCH(q) [106] si

$$r_t = \sigma_t \varepsilon_t \quad (2.20)$$

Donde

$$E(r_t|H_t) = 0 \quad (2.21)$$

$$Var(r_t|H_t) = \sigma_t^2 = \alpha_0 + \sum_{i=1}^q \alpha_i r_{t-i}^2 \quad (2.22)$$

Y el término de error ε_t está dado por,

$$E(\varepsilon_t|H_t) = 0 \quad (2.23)$$

$$Var(\varepsilon_t|H_t) = 1 \quad (2.24)$$

Las Ecuaciones (2.23) y (2.24) muestran que el término de error ε_t es una diferencia martingala, condicionalmente estandarizada, definida de la siguiente manera: una serie estocástica $\{r_t\}$ es una diferencia martingala si sus expectativas con respecto a los valores pasados de otra serie estocástica X_i es cero, es decir que [108]:

$$E(r_{t+i}|X_i, X_{i-1}, \dots) = 0 \quad (2.25)$$

Para $i = 1, 2, \dots$. En este tipo de impacto del pasado, la desviación estándar se asume como una función cuadrática de innovaciones retrasadas. El coeficiente $(\alpha_0, \alpha_1, \dots, \alpha_q)$, consistentemente, puede estimarse mediante la regresión $\{r_t^2\}$ en $r_{t-1}^2, r_{t-2}^2, \dots, r_{t-q}^2$. Para asegurar que la desviación estándar no sea negativa, se requiere $\alpha_0 \geq 0, \alpha_i \geq 0$ para todo $i = 1, 2, \dots, q$.

Basándose en la supuesta normalidad de ε_t , se adopta el método de estimación de máxima verosimilitud. Si r_1, r_2, \dots, r_t es un resultado de un proceso ARCH(1); entonces, la probabilidad de los datos puede ser escrita como un producto de las condicionales [108]:

$$f(r_1, r_2, \dots, r_t | \theta; r_1) = f(r_t | r_{t-1}) f(r_{t-1} | r_{t-2}) \dots f(r_2 | r_1) f(r_1 | \theta) \quad (2.26)$$

Donde $\theta = (\alpha_0, \alpha_1)'$.

▪ Modelo GARCH

El modelamiento ARCH, puede requerir un gran valor de retrasos q , y, por tanto, un gran número de parámetros. Esto puede resultar en un modelo con un gran número de parámetros, lo que va en contra del principio de parsimonia, lo que conlleva, muchas veces, a presentar dificultades cuando se utiliza el modelo para describir adecuadamente los datos. Un modelo GARCH puede contener menos parámetros, en comparación con un modelo ARCH; esto hace que un modelo GARCH pueda ser preferible que un modelo ARCH [108, 109].

Lo anterior no es analizado en esta investigación; aunque en [110] es discutido. El modelo GARCH (p, q) emplea la Ecuación (2.20) para los retornos logarítmicos r_t ; pero, la ecuación de desviación estándar incluye nuevos términos para q , es decir [108]:

$$r_t = \sigma_t \varepsilon_t, \varepsilon_t \sim N(0,1) \quad (2.27)$$

$$\sigma_t^2 = \alpha_0 + \alpha_1 r_{t-1}^2 + \dots + \alpha_q r_{t-q}^2 + \beta_1 \sigma_{t-1}^2 + \dots + \beta_p \sigma_{t-p}^2 \quad (2.28)$$

Donde, ahora, $t > \max(p, q)$ y los componentes restantes son como los del modelo ARCH. Los parámetros del modelo son $\alpha_0, \alpha_1, \dots, \alpha_q, \beta_1, \dots, \beta_p$, para algunos enteros positivos p, q .

▪ El Modelo GARCH (p, q)

El GARCH (p, q) es una generalización de GARCH(1,1) con p como el retraso autorregresivo y q como el retraso promedio móvil.

Formalmente, un proceso $\{r_t\}$ es GARCH(p, q) si [108]

$$r_t = \sigma_t \varepsilon_t \quad (2.29)$$

$$\sigma_t^2 = \alpha_0 + \sum_{i=1}^q \alpha_i r_{t-i}^2 + \sum_{j=1}^p \beta_j \sigma_{t-j}^2 = \alpha_0 + \alpha(B) r_t^2 + \beta(B) \sigma_t^2 \quad (2.30)$$

Donde $\alpha(B)$ y $\beta(B)$ son los polinomios en el operador dados por

$$\alpha(B) = \alpha_1 B + \dots + \alpha_q B^q \quad (2.31)$$

Y

$$\beta(B) = \beta_1 B + \dots + \beta_p B^p \quad (2.32)$$

Con las restricciones $\alpha_0 > 0$, $\alpha_i \geq 0$ y $\beta_j \geq 0$ para $i = 1, 2, \dots, q$ y $j = 1, 2, \dots, p$, impuestas con el fin de que la varianza condicional se mantenga positiva. La Ecuación (2.30) se puede expresar como [108]:

$$(1 - \beta(B))\sigma_t^2 = \alpha_0 + \alpha(B)r_t^2 \quad (2.33)$$

El modelo GARCH(0,q) es el mismo modelo ARCH(q) y, para $p=q=0$, se tiene un modelo GARCH(0,0), que es un simple ruido blanco. Al igual que en el modelo ARCH(q), la media condicional de $\{r_t\}$ es cero, es decir, $E(r_t|H_t)$ conlleva a que la serie $\{r_t\}$ sea una diferencia martingala y, al analizar $\{r_t\}$, se observa que no hay correlación [111]. Asumiendo que el proceso GARCH(p,q) es estacionario de segundo orden [108], es decir,

$$Var(r_t) = E(r_t^2) = \frac{\alpha_0}{1 - \sum_{i=1}^q \alpha_i - \sum_{j=1}^p \beta_j} \quad (2.34)$$

La autocovarianza de un modelo GARCH(p,q) para $k \geq 1$, donde k es el retraso [108], es:

$$E(r_t r_{t-k}) = 0 \quad (2.35)$$

Ya que r_t es una diferencia martingala [111]. Así, el modelo GARCH(p,q) no muestra autocorrelación en la serie de retorno $\{r_t\}$. Sin embargo, los retornos cuadrados muestran autocorrelación a pesar de que los retornos no están correlacionados.

Expresando r_t^2 en términos de $v_t = r_t^2 - \sigma_t^2$, se tiene [108],

$$r_t^2 = \sigma_t^2 + v_t = \alpha_0 + \sum_{i=1}^q (\alpha_i + \beta_i) r_{t-i}^2 - \sum_{j=1}^p \beta_j v_{t-j} + v_t \quad (2.36)$$

Donde $\alpha_i = 0$ para $i > q$, $\beta_j = 0$ para $j > p$, y v_t es otra diferencia martingala, lo que significa que $E(v_t) = 0$. Para encontrar el proceso GARCH(p,q), se resuelve α_0 en la Ecuación (2.36) y expresando la varianza de r_t como σ_ε^2 , se tiene de [108]:

$$\alpha_0 = \sigma_\varepsilon^2 \left(1 - \sum_{i=1}^q \alpha_i - \sum_{j=1}^p \beta_j \right) \quad (2.37)$$

Y sustituyendo la Ecuación (2.37) en la (2.36), se llega a:

$$E[(r_{t-k}^2 - \sigma_\varepsilon^2)(r_t^2 - \sigma_\varepsilon^2)] = E[\sum_{i,j=1}^m (\alpha_i + \beta_j)(r_{t-i}^2 - \sigma_\varepsilon^2)(r_{t-k}^2 - \sigma_\varepsilon^2)] - E[\sum_{j=1}^p \beta_j v_{t-j}(r_{t-k}^2 - \sigma_\varepsilon^2)] + E[v_t(r_{t-k}^2 - \sigma_\varepsilon^2)] \quad (2.38)$$

La autocovarianza de los retornos cuadrados para el modelo GARCH (p,q) [108] viene dada por:

$$cov(r_t^2, r_{t-k}^2) = E[\sum_{i,j=1}^m (\alpha_i + \beta_j)(r_{t-i}^2 - \sigma_\varepsilon^2)(r_{t-k}^2 - \sigma_\varepsilon^2)] \quad (2.39)$$

Por tanto, la ACF y la PACF de los retornos cuadrados en un proceso GARCH tienen el mismo patrón que las de un proceso ARIMA. Al igual que en un modelo ARIMA, la ACF y la PACF son útiles en la identificación del orden p y q del proceso GARCH(p,q).

2.2.2 Análisis no lineal

En este caso los modelos se aplican para describir el comportamiento de las series de tiempo no lineales. La no linealidad en la serie medida para la presente investigación, se observa especialmente en el análisis a corto plazo [112].

▪ Modelo de Markov

En redes de CR los estados de ocupación (ocupado o libre) están ocultos, ya que nos son directamente observables. Por tanto, el modelo de Markov ha sido usado, en redes cognitivas, para pronosticar los estados de ocupación del canal [113-116], y en [117] se ha empleado una cadena de Markov en tiempo discreto para modelar los ciclos de trabajo de canales de diferentes tecnologías inalámbricas.

Un modelo oculto de Markov (HMM) es un modelo matemático en el que el sistema que está siendo modelado contiene un proceso oculto de Markov. Los parámetros del modelo son desconocidos y deben determinarse a partir de un conjunto de datos observables. La técnica tiene su origen en el reconocimiento de voz y el procesamiento de señales, y su aplicación ha aumentado su uso en las series de tiempo. La idea principal detrás de un HMM es que el estado latente del sistema y otra información no observable se ocultan en un proceso de observación, que está afectado por algo de "ruido". Esta información

oculta se supone que sigue la dinámica de una cadena de Markov de estado finito en tiempo discreto o continuo [118].

El modelo de Markov empleado en esta tesis hace uso de un cambio de medida de probabilidad, de un filtrado recursivo y de un algoritmo de estimación; con el fin de pronosticar las diferentes potencias recibidas en canales GSM, y no los habituales estados de ocupación del canal (ocupado y libre), desarrollados en trabajos anteriores [113-116]. A continuación, se describen los componentes usados en el modelo.

▪ Cadenas de Markov

Un proceso de Markov es un proceso aleatorio sin memoria. El estado futuro del proceso depende, únicamente, de su estado actual; esto es condicionalmente independiente del pasado. Se tiene en cuenta la discusión en [119], y se asume que la cadena de Markov tiene un conjunto finito y contable de los estados.

▪ Cadenas de Markov en tiempo discreto

Sea (Ω, F, P) un espacio de probabilidad y $(X_k)_{k \in \mathbb{N}}$ una sucesión de variables aleatorias con valores en el espacio de estado $M = \{m_1, m_2, \dots, m_N\}$, donde x es una función $x: \Omega \rightarrow M$ y N es el conjunto de números naturales.

El proceso x es una cadena de Markov, si satisface la propiedad de Markov [118]

$$P(x_{k+1} = m_{x_{k+1}} | x_0 = m_0, \dots, x_k = m_k) = P(x_{k+1} = m_{x_{k+1}} | x_k = m_k) \quad (2.40)$$

$$\forall k \geq 1 \text{ y } m_0, m_1, \dots, m_k \in M$$

La distribución inicial de x está definida por $X = (X_m; m \in M)$, $X_m = P(x = m) = P(\{w: x(w) = m\})$. Además, la cadena de Markov $(X_k)_{k \in \mathbb{N}}$ se caracteriza por su matriz de probabilidad de transición Π . Para un elemento en particular π_{ji} de la matriz de probabilidad de transición Π se tiene [118],

$$\pi_{ji} = P(x_{k+1} = j | x_k = i), i, j \in M \quad (2.41)$$

Donde $\pi_{ji} \geq 0 \forall (j, i) \in M^2$ y $\sum_{j \in M} \pi_{ji} = 1 \forall i \in M$.

Esta etapa de probabilidades de transición π_{ji} s para la cadena de Markov indica la probabilidad de cambiar del estado i al estado j . La cadena de Markov es homogénea, esto es, que las probabilidades de transición $\pi_{ji} = P(x_{k+1} = j | x_k = i)$ no dependen del tiempo k .

Las probabilidades de transición de h pasos adelante pueden calcularse multiplicando la matriz Π por sí misma h veces. Esta matriz se denota por Π^h y $\pi_{ji}^{(h)} = (\Pi^h)_{ji}$ es la (j,i) entrada en la matriz de probabilidad de transición de h pasos Π^h .

Los estados de una cadena de Markov pueden ser representados por la base canónica $\{e_1, e_2, \dots, e_N\}$ de R^N , donde $e_i = (0, \dots, 0, 1, 0, \dots, 0)^T \in R^k$, donde T denota la transpuesta del vector fila. Esto se asocia con el espacio de estados M . Cuando $m_k = j$, entonces, la cadena de Markov X_k se representa por un vector unitario con el elemento 1 en la fila j , y 0 en otro lugar. La expectativa condicional de X_{k+1} es, por tanto, dada por la j th columna de la matriz de probabilidad de transición [118],

$$E(X_{k+1} | m_k = j) = \begin{bmatrix} \pi_{j1} \\ \vdots \\ \pi_{jN} \end{bmatrix} \quad (2.42)$$

Por tanto, se tiene

$$E(X_{k+1} | X_k) = E(X_{k+1} | X_k, X_{k-1}, \dots) = \Pi X_k \quad (2.43)$$

En la predicción de los estados de una cadena de Markov, representados por los vectores unitarios, se puede expresar la cadena de Markov [118] como

$$X_{k+1} = \Pi X_k + V_{k+1} \quad (2.44)$$

Donde V_k es un incremento martingala [120]. No es posible predecir V_k sobre la base de los estados anteriores del proceso y V_{k+1} puede encontrarse a partir de la siguiente diferencia [118]:

$$V_{k+1} = X_{k+1} - E(X_{k+1} | X_k, X_{k-1}, \dots) \quad (2.45)$$

La dinámica de X en la Ecuación (2.44) implica que $X_{k+h} = \Pi^h X_k + V_{k+h} + \Pi V_{k+h-1} + \Pi^2 V_{k+h-2} + \dots + \Pi^{h-1} V_{k+1}$. Ya que V_k es un incremento martingala, se deduce que la predicción del h -paso adelante de la cadena de Markov [118] está dada por:

$$E(X_{k+h} | X_k, X_{k-1}, \dots) = \Pi^h X_k \quad (2.46)$$

▪ Modelos Ocultos de Markov

En un HMM, una cadena de Markov está embebida en un proceso estocástico, el cual corresponde a una serie de observaciones. La propia cadena de Markov no es observable; esta se "oculta" en las observaciones y su objetivo es estimar la cadena de Markov subyacente, es decir, filtrar la secuencia $\{x_k\}$ de las observaciones, por lo que se asume que la cadena de Markov subyacente x_k es homogénea con espacio de estado finito en tiempo discreto. Bajo la medida del mundo real P , la cadena de Markov sigue la dinámica $X_{k+1} = \Pi X_k + V_{k+1}$, donde Π es la matriz de probabilidad de transición y V_{k+1} es un incremento martingala. El proceso de observación se denota por $\{y_k\}$ y puede seguir diferentes tipos de dinámicas.

Se destaca la importancia del número de estados N de la cadena de Markov, ya que la cadena de Markov es oculta, lo que conlleva a que el número de estados no sea observable. Una elección razonable del número de estados tiene que ser hecha sobre la base del proceso observado.

El espacio de estado M es finito, más específicamente $M = \{m_1, m_2, \dots, m_N\}$, y, como se mencionó anteriormente, puede estar asociado con la base canónica de R^N . En un HMM ergódico, todos los estados están interconectados; por lo tanto, cada estado puede ser alcanzado desde cualquier otro estado. La segunda característica en importancia de un HMM es el número M de observaciones distintas. Cuando el proceso de observación es discreto, se selecciona un conjunto de observaciones distintas. La matriz de probabilidad de transición $\Pi = \{\pi_{ji}\}$ es el tercer elemento en importancia de un HMM y define la distribución de probabilidad de transición de estado, mientras que la distribución de probabilidad del proceso de observación es el cuarto elemento clave. Por último, el HMM es caracterizado por la distribución del estado inicial $X = \{X_{ji}\}$, donde $X_j = P(x_1 = m_j)$, para todo $1 \leq j \leq N$ [118].

▪ Cambio de medida de probabilidad

A continuación se ofrece un resumen de un cambio de técnica de medición de probabilidad para el proceso de filtrado. El cambio de la técnica de medida se utiliza ampliamente en aplicaciones de filtrado y se introdujo para el filtrado estocástico en [121]. En [122], se utiliza este cambio de técnica de medida, el cual se basa en una

versión de tiempo discreto del teorema de Girsanov para derivar filtros óptimos. Esta técnica permite hacer cálculos bajo una medida matemáticamente “ideal”, denominada como una medida de probabilidad de referencia. Esta medida se usa en esta tesis para el pronóstico de la potencia recibida de tres distintos canales GSM.

Esta nueva medida de probabilidad “ideal” es equivalente a la medida del mundo real, que es la medida bajo la cual se tiene el proceso de observación. Las observaciones bajo la nueva medida son variables independientes e idénticamente aleatorias. La cadena de Markov sigue la misma dinámica tanto bajo la medida de probabilidad de referencia como la medida del mundo real. El cambio de la medida real a la medida ideal conduce a formas más fáciles de calcular filtros, como los resultados de tipo Fubini, los cuales se pueden emplear en lugar de cálculos directos, los cuales requieren métodos difíciles de semi-martingala [118].

▪ Cambio de técnicas de medición

La teoría de la evolución de las medidas se basa en la equivalencia de las dos medidas de probabilidad enlazadas a través del teorema de Radon-Nikodym [122]. Si (Ω, F) es un espacio medible, se supone a P como una medida de probabilidad sobre F . Para construir una medida de probabilidad equivalente \bar{P} en (Ω, F) se usa el siguiente teorema.

Si P y \bar{P} son dos medidas de probabilidad con $P \ll \bar{P}$, entonces existe una función no negativa f , tal que [118]

$$P(A) = \int_A f d\bar{P} \quad \forall A \in F \quad (2.47)$$

Para dos de estas funciones f y g se asume $\bar{P}(f \neq g) = 0$, por lo que la función no negativa es única.

Del anterior teorema se puede escribir [118]:

$$\int_A dP = \int_A \frac{dP}{d\bar{P}} d\bar{P} \quad \forall A \in F \quad (2.48)$$

La función medible $\frac{dP}{d\bar{P}}$ es el teorema de Radon-Nikodym derivado de P con respecto a \bar{P} . La nueva medida de probabilidad \bar{P} en (Ω, F) se define a través del teorema de Radon-Nikodym. Entonces

$$\left. \frac{d\bar{P}}{dP} \right|_F := \Lambda \quad (2.49)$$

De lo que se deduce, que [118]

$$\bar{P}(A) = \int_A \Lambda dP \quad \forall A \in F \quad (2.50)$$

Es necesario realizar las derivaciones de filtro para los procesos de la cadena de Markov, con el fin de considerar las expectativas condicionales que relacionan las dos medidas equivalentes [122].

El teorema de Bayes condicional es fundamental en la obtención de muchos resultados importantes. Para las aplicaciones de filtrado que se analizan a continuación, se necesita una versión modificada del teorema de Bayes, llamado teorema condicional de Bayes para procesos estocásticos [118].

Si se tiene:

$$\Lambda_t := E[\Lambda | F_t] \quad (2.51)$$

Donde Λ es la derivada de Radon-Nikodym $\Lambda := \frac{d\bar{P}}{dP}$. Entonces, el proceso Λ_t es un martingala.

▪ Cambio de medida para procesos de tiempo discreto

En el tiempo discreto, sea $\{X_k\}$, $k \in \mathbb{N}$, una secuencia de variables aleatorias con funciones de densidad de probabilidad (pdf) positivas Φ_k en (Ω, F, P) . Correspondiente a esta secuencia, se tiene la filtración $\{F_k\}$ generada por $\sigma\{X_1, \dots, X_k\}$. Se define una nueva medida de probabilidad \bar{P} en $(\Omega, \bigcup_{k \geq 0} F_k)$, de manera que $\{X_k\}$ es independiente e idénticamente distribuida (IID) con pdf positiva α .

Para alcanzar este objetivo, se define $\lambda_0 := 1$, $\lambda_l := \frac{\alpha(X_l)}{\Phi_l(X_l)}$ para $l \geq 1$ y $\Lambda_k := \prod_{l=0}^k \lambda_l$ [118].

Considerando,

$$\left. \frac{d\bar{P}}{dP}(w) \right|_{F_k} := \Lambda_k(w) \quad (2.52)$$

Las variables aleatorias Λ_k , $k > 0$ son P-martingalas bajo F_k y $E[\Lambda_k] = 1$. Además, de acuerdo con \bar{P} , $\{X_k\}$ es una secuencia de variables aleatorias IID con pdf α , [118].

▪ Filtros recursivos y adaptativos

Los filtros adaptativos permiten que los coeficientes se ajusten a las situaciones actuales de la serie. Este ajuste se consigue con la ayuda de un algoritmo recursivo dentro del filtro. En consecuencia, se crea un modelo de "auto-sintonizado", el cual se adapta a los cambios en los datos de la serie de tiempo. En un filtro recursivo, los valores de salida del filtro anteriores se utilizan como entradas para los cálculos.

Primero, se calculan los filtros recursivos para la expectativa condicional $\Xi_k = \bar{E}[\Lambda_k x_k | F_k^y]$. D_{k+1} es una matriz diagonal cuyos elementos d_{ij} se definen por [118]

$$d_{ij} = \begin{cases} \frac{\phi\left(\frac{y_{k+1} - f_i}{\sigma_i}\right)}{\sigma_i \phi(y_{k+1})} & \text{para } i = j \\ 0 & \text{para otro caso} \end{cases} \quad (2.53)$$

Los elementos de la matriz diagonal D_{k+1} para el caso $i=j$ son los elementos componente a componente del proceso λ_i definido por la derivada de Radon-Nikodym.

El filtro recursivo para Ξ_k , de acuerdo con [118], es:

$$\Xi_{k+1} = \Pi D_{k+1} \Xi_k \quad (2.54)$$

Con el fin de obtener estimadores recursivos óptimos para los parámetros del modelo, primero, se analiza la cadena de Markov X_k con la dinámica $X_{k+1} = \Pi X_k + V_{k+1}$. A continuación, se consideran los siguientes procesos [118, 122]:

Inicialmente, el número de saltos de una cadena de Markov, desde el estado r al estado s en el tiempo k , está definida por

$$J_k^{(sr)} := \sum_{l=1}^k \langle x_{l-1}, e_r \rangle \langle x_l, e_s \rangle \quad (2.55)$$

En segundo lugar, se tiene en cuenta el tiempo de ocupación, el cual corresponde a la longitud de tiempo x que lleva en el estado r hasta el instante k . Y está dado por

$$O_k^{(r)} := \sum_{l=1}^k \langle x_{l-1}, e_r \rangle \quad (2.56)$$

También se necesita un proceso auxiliar para estimar los vectores π , α , γ y ξ y esto tiene la forma

$$T_k^{(r)}(g) := \sum_{l=1}^k \langle x_{l-1}, e_r \rangle g(y_l) \quad (2.57)$$

Donde g es una función, que es $g(y)=y$ o $g(y)=y^2$.

Para cualquier proceso H_k F_k^y -adaptado, se escribe $\hat{H}_k := E[H_k | F_k^y]$. La expectativa condicional de H_k dado F_k^y se denota por $\eta_k(H_k) := \bar{E}[\wedge_k H_k | F_k^y]$. A continuación se desarrollan relaciones recursivas para las expectativas condicionales de los procesos definidos anteriormente.

Aplicando el teorema de Bayes [118], se considera,

$$\hat{f}_k^{(sr)} = E[J_k^{(sr)} | F_k^y] = \frac{\bar{E}[\wedge_k J_k^{(sr)} | F_k^y]}{\bar{E}[\wedge_k | F_k^y]} \quad (2.58)$$

Aunque no se puede encontrar una expresión recursiva para $\bar{E}[\wedge_k J_k^{(sr)} | F_k^y]$, se encuentra una para el proceso vectorial $\bar{E}[\wedge_k J_k^{(sr)} x_k | F_k^y] = \eta_k(J_k^{(sr)} x_k)$.

Las relaciones recursivas para $\eta_k(J_k^{(sr)} x_k)$, $\eta_k(O_k^{(r)} x_k)$ y $\eta_k(T_k^{(r)} x_k)$, tomadas de [118], se presentan a continuación.

Si D es la matriz diagonal definida anteriormente, entonces:

$$\eta_l(J_l^{(sr)} x_l) = \Pi D_l(y_l) \eta_{l-1}(J_{l-1}^{(sr)} x_{l-1}) + \langle \Xi_{l-1}, e_r \rangle \frac{\phi(\sigma_r^{-1}(y_l - f_r))}{\sigma_r \phi(y_l)} \pi_{sr} e_s \quad (2.59)$$

$$\eta_l(O_l^{(r)} x_l) = \Pi D_l(y_l) \eta_{l-1}(O_{l-1}^{(r)} x_{l-1}) + \langle \Xi_{l-1}, e_r \rangle \frac{\phi(\sigma_r^{-1}(y_l - f_r))}{\sigma_r \phi(y_l)} \Pi e_r \quad (2.60)$$

Y

$$\eta_l(T_l^{(r)}(g) x_l) = \Pi D_l(y_l) \eta_{l-1}(T_{l-1}^{(r)}(g) x_{l-1}) + \langle \Xi_{l-1}, e_r \rangle \frac{\phi(\sigma_r^{-1}(y_l - f_r))}{\sigma_r \phi(y_l)} g(y_l) \Pi e_r \quad (2.61)$$

▪ Movimiento Browniano

Este tipo de modelos se pueden expresar, según [123], mediante la siguiente ecuación estocástica diferencial:

$$dr_t = [\theta_t - \alpha_t r_t]dt + u_t dW_t \quad (2.62)$$

W_t es el movimiento Browniano bajo una medida de probabilidad P , r_t es un proceso de Markov. Los parámetros α_t , θ_t y u_t son funciones deterministas de tiempo t .

▪ Modelo de régimen de conmutación

El modelo de series de tiempo general para los cambios en los regímenes sigue un proceso de primer orden autorregresivo [120], donde el término constante y el coeficiente autorregresivo pueden ser diferentes para distintos regímenes. El modelo para el proceso A_t como se indica en [118], toma la forma

$$A_t = c_{N_t} + \phi_{N_t} A_{t-1} + \varepsilon_t \quad (2.63)$$

El término del error ε_t es IID y sigue una distribución $N(0, \sigma^2)$. Los diferentes regímenes se denotan por el subíndice N_t , el cual se modela como un resultado de una cadena de Markov no observada con N estados.

En el modelo propuesto, se considera la dinámica estocástica de r_t dada en la Ecuación (2.62). Reordenando la formula se tiene [118]

$$dr_t = \alpha_t [\delta_t - r_t]dt + u_t dW_t \quad (2.64)$$

Donde $\delta = \frac{\theta}{\alpha}$. La Ecuación (2.64) es un caso particular de un proceso de Ornstein-Uhlenbeck, con un nivel de reversión media δ [118]. Cuando los parámetros son constantes se tiene la solución:

$$P_{Rx_t} = P_{Rx_0} e^{-\alpha t} + (1 - e^{-\alpha t})\delta + u e^{-\alpha t} \int_0^t e^{\alpha u} dW_u \quad (2.65)$$

A partir de la especificación de [123], se desarrolla un modelo oculto de Markov para la potencia recibida P_{Rx} , donde P_{Rx} corresponde a una serie de datos en tiempo discreto.

Un estado N de una cadena de Markov de tiempo discreto X_k , que representa diferentes estados de la potencia recibida en el canal, se oculta en los valores observados. X_k es

una cadena de Markov homogénea con estados finitos en tiempo discreto ($k = 0, 1, \dots$). La distribución de x_0 es conocida y el espacio de estados de X_k se describe por la base canónica de \mathbb{R}^N , $\{e_1, e_2, \dots, e_N\}$. Por una parte, $F_k^0 = \sigma\{X_0, \dots, X_k\}$ es el σ -campo generado por X_0, \dots, X_k , y F_k^x es la filtración completa generada por F_k^0 . De otra parte, R_k denota la filtración completa generada por P_{Rx} , de modo que $H_k = F_k^x \vee R_k$ es la filtración global generada por x y P_{Rx} , donde H es un proceso estocástico adaptado [118].

La potencia recibida P_{Rx} con los parámetros del régimen de conmutación sigue el proceso estocástico [118]

$$dP_{Rxt} = \alpha(x_t)[\delta(x_t) - P_{Rxt}]dt + u(x_t)dW_t \quad (2.66)$$

Para $P_{Rx0} \geq 0$ con $\alpha(x_t) = \langle a, x_t \rangle$, $\delta(x_t) = \langle \delta, x_t \rangle$ y $u(x_t) = \langle u, x_t \rangle$, donde $\langle \cdot, \cdot \rangle$ es el usual producto escalar Euclidiano. Los tres parámetros se rigen por una cadena de Markov, la cual asegura que el modelo está cambiando de una potencia a otra a través del tiempo.

Se considera el proceso de potencia de recepción durante el intervalo de tiempo $[s, t]$. Por ende, si $t-s$ es pequeña y x es constante sobre el intervalo, la solución del proceso estocástico en la Ecuación (2.66), teniendo en cuenta la Ecuación (2.65), es [118]:

$$P_{Rx_t} = e^{-\alpha(x_s)(t-s)}P_{Rx_s} + \delta(x_s)(1 - e^{-\alpha(x_s)(t-s)}) + u(x_s)e^{-\alpha(x_s)t} \int_s^t e^{\alpha(x_s)u} dW_u \quad (2.67)$$

La integral estocástica $e^{-\alpha(x_s)t} \int_s^t e^{\alpha(x_s)u} dW_u$ es normalmente distribuida con media cero y varianza

$$\int_s^t e^{2\alpha(x_s)(u-t)} du = \frac{1 - e^{-2\alpha(x_s)(t-s)}}{2\alpha(x_s)} \quad (2.68)$$

De la Ecuación (2.67), la representación en tiempo discreto del proceso de potencia de recepción se obtiene a partir de [118]

$$P_{Rx_{k+1}} = \alpha(x_k)P_{Rx_k} + \gamma(x_k) + \xi(x_k)w_{k+1} \quad (2.69)$$

Donde

$$\alpha(x_k) = e^{-\alpha(x_k)\Delta} \quad (2.70)$$

$$\gamma(x_k) = \delta(x_k)(1 - e^{-\alpha(x_k)\Delta}) \quad (2.71)$$

Y

$$\xi(x_k) = u(x_k) \sqrt{\frac{1 - e^{-2\alpha(x_k)\Delta}}{2\alpha(x_k)}} \quad (2.72)$$

Aquí, $\{x_k\}$ es un tiempo discreto de la cadena de Markov y $\{w_k\}$ es una secuencia de variables aleatorias normales estándar IID. Para esta versión de tiempo discreto, los parámetros óptimos se pueden derivar con técnicas de filtrado [118].

La estimación de los parámetros π_{ji} , α_i , γ_i y ξ_i , para el proceso de observación, se realiza usando el algoritmo de expectativa de maximización (EM).

▪ Estimaciones de los parámetros del modelo

Se necesitan las relaciones recursivas de los procesos de la cadena de Markov, considerados en las Ecuaciones (2.59), (2.60) y (2.61), para derivar estimadores recursivos óptimos de los parámetros del modelo, [118], que son:

1. Matriz de transición $\Pi = (\pi_{ji})$,
2. Parámetros de la potencia recibida discreta α , γ , ξ .

Las estimaciones de los parámetros óptimos se obtienen a través de la técnica de estimación de máxima verosimilitud (EMV). El método utilizado para calcular la EMV es el llamado algoritmo EM, que se describe a continuación.

▪ Algoritmo expectativa de maximización

Este algoritmo se aplica para derivar estimaciones de los parámetros óptimos para el parámetro de modelo ajustado $\hat{\theta} = \{\hat{\pi}_{ji}, \hat{\gamma}_i, \hat{\alpha}_i, \hat{\xi}_i \mid 1 \leq i, j \leq n\}$. El algoritmo EM es un procedimiento iterativo para encontrar el EMV en problemas de datos incompletos, donde el cálculo de EMV podría ser difícil a causa de los valores faltantes o donde la optimización de la función de verosimilitud es analíticamente intratable [124].

Acá θ corresponde a un conjunto de parámetros en el espacio de parámetros Θ . $\{P^\theta, \theta \in \Theta\}$ es una familia de medidas de probabilidad en un espacio medible (Ω, \mathcal{F}) , lo que es absolutamente continuo con respecto a una medida de probabilidad fija P^0 y con $\gamma \in \mathcal{F}$.

Para calcular una estimación óptima de θ . La función de probabilidad para calcular θ sobre la base de la información contenida en γ está dada por [118]

$$F(\theta) = E^0 \left[\frac{dP^\theta}{dP^0} \middle| \gamma \right] \quad (2.73)$$

Y el estimador de máxima verosimilitud de θ se define por

$$\hat{\theta} \in \underset{\theta \in \Theta}{\operatorname{argmax}} F(\theta) \quad (2.74)$$

Sin embargo, el estimador no es sencillo de calcular. El algoritmo EM se acerca indirectamente al problema con un método de aproximación iterativa [125].

Se establece $m = 0$ y se selecciona $\hat{\theta}_0$. Para cada iteración, el algoritmo EM consta de dos pasos: la etapa de expectativa (E) y la etapa de maximización (M)[118].

1. En la etapa de expectativa, se coloca $\theta^* = \hat{\theta}_m$ y se determina la función $Q(\theta, \theta^*)$.

$$Q(\theta, \theta^*) = E^{\theta^*} \left[\log \frac{dP^\theta}{dP^{\theta^*}} \middle| \gamma \right] \quad (2.75)$$

2. En la etapa de maximización, se encuentra algún valor de $\theta \in \Theta$ que maximiza $Q(\theta, \theta^*)$, es decir,

$$\hat{\theta}_{m+1} \in \underset{\theta \in \Theta}{\operatorname{argmax}} Q(\theta, \theta^*) \quad (2.76)$$

Por último, se sustituye m por $m+1$ y se repite las E- y M-etapas hasta que algún criterio de parada sea satisfecho.

Como se muestra en [126], la secuencia $\{\hat{\theta}_m\}$ arroja valores no decrecientes de la función de probabilidad, los cuales convergen a un máximo local de la función de probabilidad. Un algoritmo conocido para la estimación de parámetros en HMM es el algoritmo de [127]. Este algoritmo es un caso particular del algoritmo generalizado EM para HMMs. Este es un algoritmo de avance-retroceso que calcula las probabilidades de avance y retroceso para cada estado del HMM; a su vez, utiliza estas probabilidades para calcular la EMV de los parámetros [128]. Ahora, en el modelo propuesto, los parámetros se pueden optimizar mediante la aplicación del algoritmo EM para $\log \frac{dP^\theta}{dP^{\hat{\theta}}}$, con el previamente definido $\hat{\theta}$. El objetivo es encontrar $\hat{\theta}$ que maximiza la función Q [118].

▪ Estimaciones de los parámetros óptimos

Se lleva a cabo un cambio de medida, como se describió anteriormente. Según P^θ , x es una cadena de Markov, con matriz de transición $\Pi = (\pi_{ji})$. Se introduce una nueva medida de probabilidad $P^{\hat{\theta}}$ y, de acuerdo con $P^{\hat{\theta}}$, x es una cadena de Markov con matriz de transición $\hat{\Pi} = (\hat{\pi}_{ji})$. En otras palabras, $P^{\hat{\theta}}(x_{k+1} = e_j | x_k = e_i) = \hat{\pi}_{ji}$. Por tanto, $\hat{\pi}_{ji} \geq 0$ y $\sum_{j=1}^n \hat{\pi}_{ji} = 1$.

En esta situación [118],

$$\left. \frac{dP^{\hat{\theta}}}{dP^\theta} \right|_{F_k} = \Lambda_k, \Lambda_0 = 1 \text{ y } \Lambda_k = \prod_{l=1}^k \left(\prod_{s,r=1}^n \left(\frac{\hat{\pi}_{sr}}{\pi_{sr}} \right)^{(x_l, e_s)(x_{l-1}, e_r)} \right) \quad (2.77)$$

Cuando $\pi_{ji} = 0$, se asume $\hat{\pi}_{ji} = 0$ y $\frac{\hat{\pi}_{ji}}{\pi_{ji}} = 1$. Las estimaciones óptimas para los parámetros del modelo se obtienen mediante lo siguiente [118, 122]:

Si una secuencia de observaciones y_1, y_2, \dots, y_k está disponible en el instante k , y el conjunto de parámetros $\{\hat{\pi}_{ji}, \hat{\alpha}_i, \hat{\gamma}_i, \hat{\xi}_i\}$ determinan el modelo; entonces, las estimaciones EM del filtro para estos parámetros están dados por:

$$\hat{\pi}_{ji} = \frac{j_k^{(ji)}}{\hat{o}_k^{(i)}} = \frac{\eta_k(j_k^{(ji)})}{\eta_k(o_k^{(i)})} \quad (2.78)$$

$$\hat{\alpha}_i = \frac{\eta_k(T_k^{(i)}(y_{k+1}, y_k)) - \eta_k(T_k^{(i)}(y)) \hat{\gamma}_i}{\eta_k(T_k^{(i)}(y^2))} \quad (2.79)$$

$$\hat{\gamma}_i = \frac{\eta_{k+1}(T_{k+1}^{(i)}(y)) - \eta_k(T_k^{(i)}(y)) \hat{\alpha}_i}{\eta_k(o_k^{(i)})} \quad (2.80)$$

Y

$$\hat{\xi}_i = \frac{\eta_{k+1}(T_{k+1}^{(i)}(y^2)) + \hat{\alpha}_i^2 \eta_k(T_k^{(i)}(y^2)) + \hat{\gamma}_i^2 \eta_k(o_k^{(i)}) - 2\hat{\alpha}_i \eta_k(T_k^{(i)}(y_{k+1}, y_k))}{\eta_k(o_k^{(i)})} - \frac{2\hat{\gamma}_i \eta_{k+1}(T_{k+1}^{(i)}(y)) + 2\hat{\alpha}_i \hat{\gamma}_i \eta_k(T_k^{(i)}(y))}{\eta_k(o_k^{(i)})} \quad (2.81)$$

Los resultados anteriores no solo proporcionan estimaciones de la cadena de Markov, sino que también actualizan los parámetros del modelo [118].

▪ **Modelo de descomposición de modo empírico y vector de soporte para regresión**

El modelo de vector de soporte para regresión (SVR) es un método adecuado para el pronóstico de señales no estacionarias y, a su vez, la descomposición de modo empírico (EMD) ha sido usada para el análisis de señales no lineales y no estacionarias. Para sistemas cognitivos, en [129] se propone el uso de un nuevo algoritmo que combina los métodos anteriores, llamado EMD-SVR y el cual pronostica la señal de un sistema de monitorización de frecuencia de radar.

▪ **Descomposición del modo empírico**

El principio de la EMD es descomponer una señal $x(t)$ en una suma de funciones que satisface dos condiciones [130]:

1. El número de extremos y el número de cruces por cero debe ser igual o diferir en más de uno;
2. El valor medio de la envolvente definida por los máximos locales y los mínimos locales es cero [130].

Estas funciones se conocen como funciones de modo intrínsecas (IMF), y se denotan $imf_i(t)$. Las IMF se obtienen utilizando el siguiente algoritmo [131]:

1. Inicializar: $r_0(t)=x(t), i=1$
2. Extraer el i -th IMF:
 - (a) Inicializar: $h_0(t)=r_{i-1}(t), j=1$
 - (b) Extraer los mínimos y máximos locales de $h_{j-1}(t)$
 - (c) Interpolar los máximos locales y los mínimos locales por un *spline* cúbico para formar envolventes superiores e inferiores de $h_{j-1}(t)$
 - (d) Calcular la media $m_{j-1}(t)$ de las envolventes superiores e inferiores
 - (e) $h_j(t)=h_{j-1}(t)-m_{j-1}(t)$
 - (f) Si al detenerse, el criterio es satisfecho, establecer entonces $imf_i(t)=h_j(t)$, sino ir a (b) con $j=j+1$

3. $r_i(t) = r_{i-1}(t) - \text{imf}_i(t)$
4. Si $r_i(t)$ todavía tiene al menos 2 extremos entonces ir al paso 2 con $i=i+1$; de otra forma, la descomposición ha finalizado y $r_i(t)$ es el residuo.

Al final del algoritmo se obtiene,

$$x(t) = \sum_{i=1}^n \text{imf}_i(t) + r_n(t) \quad (2.82)$$

Donde $r_n(t)$ es el residuo de la descomposición, que puede ser la tendencia media o una constante.

▪ Vector de soporte para regresión

Se considera un conjunto de datos de entrenamiento $\{(x_i, y_i)\}_{i=1}^N$, donde cada $x_i \in \mathbb{R}^n$ denota un valor de entrada y tiene un valor objetivo correspondiente $y_i \in \mathbb{R}$. El SVR genérico construye una función lineal [132]:

$$f(x) = \langle w, \Phi(x) \rangle + b \quad (2.83)$$

Donde $\Phi(\cdot)$ es un mapeo no lineal de \mathbb{R}^n a un mayor espacio dimensional llamado espacio de características. El vector de regresión w ($w \in \mathbb{R}^n$) y el término de tendencia b ($b \in \mathbb{R}$) dan las soluciones al siguiente problema de optimización convexa [133]:

$$\begin{aligned} \min_{w, \xi_i, \xi_i^*} L &= C \sum_{i=1}^N (\xi_i + \xi_i^*) + \frac{1}{2} \|w\|^2 \\ &\begin{cases} y_i - \langle w, \Phi(x_i) \rangle - b \leq \varepsilon + \xi_i \\ \langle w, \Phi(x_i) \rangle + b - y_i \leq \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0 \end{cases} \end{aligned} \quad (2.84)$$

Donde el parámetro ε ajusta el tamaño del error de aproximación de la regresión para controlar el número del vector de soporte y la capacidad de generalización. Cuanto más grande es el valor de ε , la precisión es más baja. La presencia de errores en el conjunto de datos se mide por otros parámetros internos ξ_i y ξ_i^* llamados "variables de holgura", que caracterizan la desviación de muestras de entrenamiento fuera del ε -margen [133].

El término C en la Ecuación (2.84) es una constante, que determina sanciones a los errores de estimación. Un término C considerable asigna grandes sanciones a los

errores, de forma que la regresión es entrenada para minimizar el error con una menor generalización; mientras que un término C pequeño asigna un menor número de sanciones a los errores [132]. En el estándar SVR, los valores de ε y C se deben especificar de antemano.

El problema de optimización anterior, se puede resolver más fácilmente con esta doble formulación [132]:

$$\max_{a_i, a_i^*} L = -\frac{1}{2} \sum_{i,j=1}^N (a_i^* - a_i)(a_j^* - a_j) (\Phi(x_i), \Phi(x_j)) - \sum_{i=1}^N (a_i^*(y_i - \varepsilon) - a_i(y_i + \varepsilon))$$

Teniendo en cuenta que:

$$\sum_{i=1}^N (a_i - a_i^*) = 0, a_i, a_i^* \in [0, C] \quad (2.85)$$

Donde las variables a_i y a_i^* se determinan mediante técnicas de programación cuadrática. Entonces, la solución del vector w y la función de regresión SVR se obtienen de las siguientes expresiones [132]:

$$w = \sum_{i=1}^N (a_i - a_i^*) \Phi(x_i) \quad (2.86)$$

$$f(x) = \sum_{i=1}^N (a_i - a_i^*) \langle \Phi(x_i), \Phi(x) \rangle + b \quad (2.87)$$

En la Ecuación (2.87), el producto escalar en el espacio característico $\langle \Phi(x_i), \Phi(x) \rangle$ puede ser reemplazado por una función kernel $k(x_i, x)$. Las funciones kernel permiten que el producto punto se realice en el espacio característico de alta dimensión, usando datos de entrada del espacio, de bajas dimensiones, sin conocer la transformación Φ [132]. La función kernel más utilizada es la función de base radial (RBF) gaussiana con un ancho σ [132]:

$$k(x, x_i) = \exp \left\{ -\frac{|x - x_i|^2}{\sigma^2} \right\} \quad (2.88)$$

▪ Vector de soporte para regresión en el pronóstico de series de tiempo

Para el modelado y pronóstico de una serie de tiempo no lineal, es fundamental la reconstrucción del espacio de fase (PSR) [134]. En términos generales, es probable que la dimensión del espacio de fase de las series de tiempo no lineales sea muy alta, incluso

infinita, lo que no se conoce en la mayoría de casos. Así que, la información oculta en las series de tiempo solo puede ser descubierta, cuando la serie de tiempo se expande al espacio multidimensional [135]. Este es el PSR de series de tiempo. Por tanto, el PSR permite hacer un pronóstico a corto plazo del comportamiento futuro de una serie de tiempo, usando la información basada solamente en los valores pasados [129].

El espacio de reconstrucción de fase tradicional, generalmente, adopta el método llamado retardo de coordenadas (CD) [135]. Dada una serie de tiempo $\{x_t\}_{t=1}^N$, reconstruir el vector de características

$$X_t = (x_t, x_{t-1}, \dots, x_{t-(m-1)}) \quad (2.89)$$

(m está incorporando la dimensión, el tiempo de retardo se establece en 1; $t = m, m + 1, \dots, N - 1$), modelando series de tiempo, consiste en encontrar una función $f: \mathbb{R}^m \rightarrow \mathbb{R}$ entre la entrada auto-correlativa X_t y la salida Y_t , tal que

$$Y_t = x_{t+1} = f(x_t, x_{t-1}, \dots, x_{t-(m-1)}) = f(X_t) \quad (2.90)$$

Al aplicar el SVR para tratar el conjunto de datos de entrenamiento $\{(X_t, Y_t)\}_{t=m}^N$, se puede construir un modelo de pronóstico de series de tiempo, de la siguiente forma [136]:

$$Y_N = \hat{x}_{N+1} = \sum_{i=1}^{N-m} (a_i - a_i^*) K(X_N, x_i) + b \quad (2.91)$$

Donde $X_N = (x_N, x_{N-1}, \dots, x_{N-(m-1)})$.

▪ Modelo de pronóstico EMD-SVR

El modelo de pronóstico EMD-SVR, como se presenta en la Figura 2-2, utiliza, principalmente, el algoritmo de la EMD para descomponer las series de datos $\{x_1, \dots, x_l\}$ en un conjunto finito de IMF; luego, se realizan los pronósticos de estas IMF con el modelo SVR para obtener el valor pronosticado $\widehat{imf}_l(l+1)$, y, finalmente, de acuerdo con la Ecuación (2.82), el valor pronosticado $\hat{x}(l+1)$ se encuentra con la suma de los resultados pronosticados anteriormente [129].

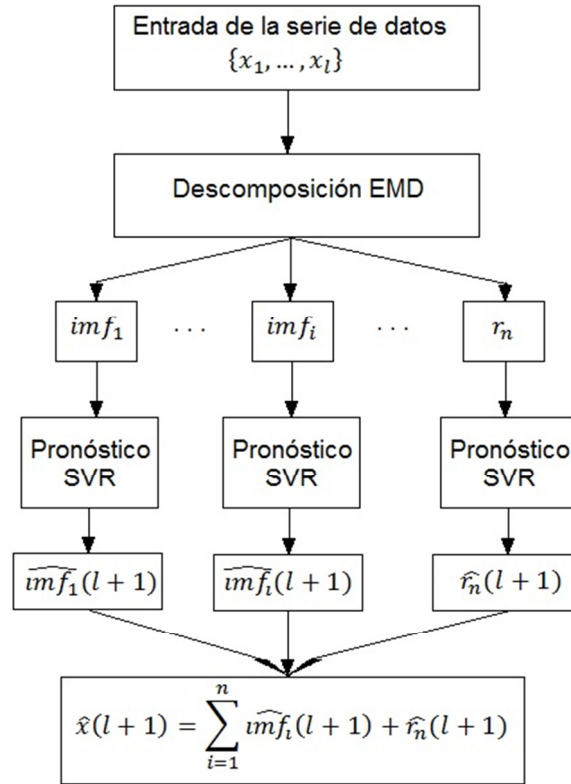


Figura 2-2: Diagrama de flujo del modelo EMD-SVR [129].

Usando la EMD, pueden mostrarse, en diferentes escalas, las distintas características de la información de los datos sin procesar, por lo que este método puede capturar mejor las fluctuaciones locales de los datos sin procesar; además, cada IMF tiene características de frecuencia similares, componentes de frecuencia más simples y una fuerte regularidad; por lo tanto, este modelo puede reducir la complejidad del modelado SVR y mejorar la eficiencia y precisión del pronóstico SVR [129].

▪ Modelo neuronal wavelet

Para sistemas cognitivos, en [137], se hace uso de una red neuronal de propagación hacia atrás para predecir el estado del espectro, y en [138, 139] se optimiza la red neuronal con un algoritmo genético. Igualmente, en [140], se hace uso de una red neuronal para pronosticar la potencia en las bandas de televisión y GSM900. Finalmente, en [141] se modela y pronostica el espectro utilizando las *wavelets Daubechies*.

Lo anterior, demuestra el carácter promisorio de las redes neuronales y las *wavelets* en el pronóstico de la potencia recibida en canales inalámbricos. Por tanto, en esta tesis se propone el uso de una teoría que combina las disciplinas *wavelets* y redes neuronales [142], para pronosticar la potencia recibida en canales GSM. En seguida, se detallan los métodos que componen el modelo neuronal wavelet.

▪ Wavelet

Las *wavelets* son una clase de funciones usadas para localizar una determinada función tanto en la posición como en la escala. Las *wavelets* son la base de la transformada wavelet que “divide los datos de las funciones u operadores en diferentes componentes de frecuencia, y entonces estudia cada componente con una resolución igual a la de su escala” [142, 143].

Una wavelet es una función de “pequeña señal”, usualmente denotada $\psi(\cdot)$. Una pequeña señal crece y decae en un período de tiempo finito, en oposición a una “gran señal”, tal y como la señal seno, la cual crece y decae en varias ocasiones durante un período de tiempo infinito. La función $\psi(\cdot)$, generalmente, se refiere como la wavelet madre. Una familia de *wavelets* puede ser creada por traslación y expansión de esta wavelet madre [144].

La transformada wavelet discreta (DWT) usa *wavelets* madre como *Haar*, *Daubechies*, *Coefiman*, entre otras. Con DWT, se analiza una señal en diferentes bandas de frecuencia, con diferentes resoluciones para descomponer la señal en alta escala, que son componentes de baja frecuencia llamados coeficientes aproximados; y de baja escala, que son componentes de alta frecuencia llamados coeficientes detallados. Por tanto, la transformada wavelet es una implementación de un banco de filtros que descompone una señal en múltiples señales [145]. Los coeficientes wavelet se pueden expresar como [146]:

$$W_{\phi}[j_0, k] = \frac{1}{\sqrt{M}} \sum_n f[n] \phi_{j_0, k}[n] \quad (2.92)$$

$$W_{\psi}[j, k] = \frac{1}{\sqrt{M}} \sum_n f[n] \psi_{j, k}[n] \quad j \geq j_0 \quad (2.93)$$

Donde $f[n]$ es la proyección de la muestra en el dominio del tiempo, $\phi_{j_0, k}$ es la función de escala y $\psi_{j, k}$ es la función de traslación, las cuales son funciones discretas definidas entre

$[0, M-1]$, para el total de M puntos. Los coeficientes de la Ecuación (2.92) son los coeficientes de aproximación, mientras que los de la Ecuación (2.93) son los coeficientes detallados.

▪ Red neuronal

Una red neuronal artificial (ANN) es una red distribuida en paralelo de unidades de procesamiento conectadas, llamadas neuronas. Esta está motivada por el proceso cognitivo humano: el cerebro humano es muy complejo, no lineal y paralelo. La red tiene una serie de entradas y salidas externas que toman o suministran información al entorno circundante. Las conexiones inter-neuronas se llaman sinapsis, que tienen asociado pesos sinápticos. Estos pesos se utilizan para almacenar el conocimiento que se adquiere desde el entorno. El aprendizaje se logra ajustando estos pesos de acuerdo con un algoritmo de aprendizaje. También es posible, para las neuronas, evolucionar mediante la modificación de su propia topología; esta evolución está motivada por el hecho de que las neuronas en el cerebro humano pueden morir y pueden crecer nuevas sinapsis [144].

Por lo general, se necesita un número de entradas/destino para entrenar una red. Una neurona recibe la información numérica a través de un número de nodos de entrada, la procesa internamente, y se obtiene una respuesta. El procesamiento se realiza, usualmente, en dos etapas: primero, los valores de entrada se combinan linealmente, y luego, el resultado se utiliza como argumento de una función de activación no lineal. La combinación utiliza los pesos atribuidos a cada conexión, y un término constante. La Figura 2-3 muestra uno de los esquemas más utilizados para representar una neurona [147].




Figura 2-3: Modelo de una neurona [147].

La salida de la neurona de la Figura 2-3 está dada por:

$$y = f[(\sum_{i=1}^n w_i x_i - \theta)], i = 1, 2, 3 \dots n \quad (2.94)$$

Donde x_i es la entrada a la neurona, w_i es el peso, θ es el offset y f es la función de activación.

▪ Redes multi-capa de alimentación hacia adelante

Las redes neuronales de alimentación hacia adelante contienen una o más capas ocultas, cuyos nodos de cómputo son llamados neuronas ocultas. Las neuronas ocultas intervienen entre las capas de entrada y las de salida, lo que le permite, a la red, extraer estadísticas de orden superior. Normalmente, las neuronas, en cada capa de la red, tienen como entradas únicamente las señales de salida de las neuronas de la capa anterior. La Figura 2-4 muestra un ejemplo con una capa oculta. Esto se refiere a una red 3-3-2, compuesta por 3 nodos de origen, 3 neuronas ocultas (en la primera capa oculta) y 2 neuronas de salida [144].

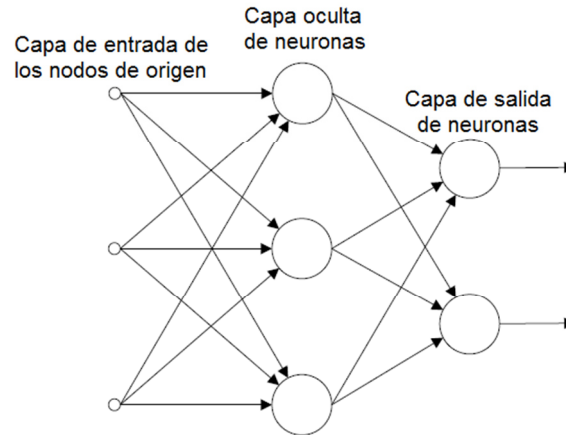


Figura 2-4: Red neuronal multi-capa de alimentación hacia adelante [144].

El modelo neuronal de esta investigación hace uso de una red neuronal multi-capa de propagación hacia atrás, cuyo error en la salida se propaga hacia atrás, para ajustar los pesos que conllevan a minimizar el error. Las redes de propagación hacia atrás aprenden con el método de gradiente descendente, el cual define cómo se realiza el entrenamiento para los nodos de salida en una red multicapa [148].

▪ Red neuronal wavelet

Las redes neuronales wavelet combinan la teoría de *wavelets* y redes neuronales. Para el modelo propuesto en la presente investigación, se lleva a cabo por separado el procesamiento wavelet y de redes neuronales. La señal de entrada, primero, se descompone usando una wavelet madre; luego, los coeficientes se envían a la entrada de la red neuronal multi-capa de propagación hacia atrás; finalmente, la salida de la red neuronal es reconstruida usando el análisis wavelet para obtener el pronóstico de la potencia de los canales GSM.

3. Análisis estadístico para las mediciones de la red móvil

A partir de la campaña de mediciones de espectro, realizadas en la ciudad de Bogotá-Colombia, durante el estudio de ocupación del espectro [13, 149, 150], se decide analizar la banda GSM 850MHz, puesto que es una banda en constante uso y viable de analizar en función del tiempo, con equipos de medida convencionales como el analizador de espectro. Las medidas usadas en este estudio corresponden a las de una semana que va desde el 23 hasta el 29 de diciembre de 2012. En algunos estudios [6], se ha indicado que una opción razonable para obtener resultados representativos sin ninguna información a priori de la banda a medir, es considerar periodos de medición de, al menos, 24 horas a fin de no subestimar o sobrestimar la ocupación de bandas de frecuencia con algunos patrones temporales. Aunque un período de medición de 24 horas puede considerarse adecuado, para caracterizar correctamente la actividad de las bandas del espectro determinado; en esta investigación, se analizan 7 días, lo que incluye patrones de uso en los días entre semana y el fin de semana; adicionalmente, es un tiempo suficiente para medir la ocupación hasta en redes móviles de poco uso, tal como se indica en ITU-R [151].

En este Capítulo, se presenta, inicialmente, la metodología con la que se realizó la medición del espectro radioeléctrico; posteriormente, se efectúa un análisis estadístico de los canales seleccionados.

3.1 Metodología para medición del espectro radioeléctrico

El procedimiento de medición del espectro radioeléctrico es descrito a continuación y los resultados de medición de las bandas móviles son usados para el análisis de esta investigación.

Los rangos de medición de las bandas se basaron en aspectos como: el tiempo de barrido, el ancho de banda de resolución (RBW) y el *span*, con el fin de garantizar una adecuada medida en función del piso de ruido y del ancho de banda del canal de la tecnología a medir [6]. La configuración de la medición se muestra en la Figura 3-1 y las especificaciones técnicas de los dispositivos usados se pueden observar en la Tabla 3-1. Como se espera, el analizador de espectro proporciona la detección basada en energía a fin de indicar si las señales están presentes o ausentes [149].




Figura 3-1: Configuración de la medición [149].

Tabla 3-1: Especificaciones de los equipos de medida [149].

Equipos	Especificaciones	
	Rango de Frecuencia	Referencia
Antena tipo discono	25 MHz – 6 GHz	Super-M Ultra Base
Cable de banda ancha	DC – 18 GHz	CBL-6FT SMNM+
Amplificador de bajo ruido	20 MHz – 8 GHz	ZX60-8008E-S+
Analizador de espectro	9 kHz – 7.1 GHz	MS2721B Anritsu

A continuación se describen las variables características que se consideraron en este estudio [6].

3.1.1 Frecuencia

La ocupación del espectro se midió en el intervalo de 54MHz a 6 GHz. El *span* para cada medición fue menor a 100MHz y fue calculado a partir de las Ecuaciones (3.1) y (3.2) cuando la tecnología a medir es conocida, con el fin de garantizar un estimado preciso de ocupación.

$$AB_T > f_b \quad (3.1)$$

$$f_b = \frac{SPAN}{pps-1} \quad (3.2)$$

Donde AB_T es el ancho de banda del canal de la tecnología a medir, f_b es el *bin* de frecuencia y *pps* es el número de puntos por *span* del analizador, el cual, para este caso, es 551. Dichos segmentos menores a 100MHz permitieron escoger el $RBW \leq AB_T$, el cual estuvo alrededor de $3\text{kHz} \leq RBW \leq 100\text{kHz}$, con tiempos de barrido que oscilaron entre 290 milisegundos y 5.124 segundos [149].

3.1.2 Localización

Las mediciones de la banda móvil se realizaron en un sitio residencial del norte de la ciudad de Bogotá; las coordenadas de dicho estudio son: latitud = 4°43'51" norte, longitud = 74°3'24" oeste, altitud = 2578 metros. Este sitio fue seleccionado por sus características urbanas, puesto que presenta no solo edificaciones sino zonas verdes, descritas en el Capítulo 4. A su vez, en este lugar, se facilitó el almacenamiento de las mediciones durante las 24 horas del día.

3.1.3 Amplitud

Los niveles de potencia se ajustaron en cada segmento del analizador de espectro, sin exceder los niveles de señal que permite el analizador; pues, de lo contrario, se producen espurios mayores que la variación promedio de piso de ruido, para cada medida. Estudios

de espectro previos [6] sugieren que un buen criterio para configurar el rango dinámico de un analizador de espectro, al que se le conecta un amplificador a la entrada, es ajustar los niveles de potencia para que las señales se encuentren dentro del margen dinámico libre de espurios (SFDR), el cual se calcula como:

$$SFDR(dB) = P_I(dBm) - P_N(dBm) \quad (3.3)$$

Donde, P_I es la potencia de la señal a la entrada y P_N es la potencia de ruido equivalente a la entrada. El objetivo es tener tanta sensibilidad, como sea posible, en el receptor, con el uso del amplificador, evitando que los niveles de espurios puedan ser detectados como actividad de un PU. El ruido promedio del instrumento para cada medida es determinado con la ubicación de una impedancia de 50Ω a la entrada del analizador de espectro, con una atenuación de 0 dB, detección de valor cuadrático medio (RMS) y un tiempo de medición de 6h [149].

La Figura 3-2 muestra una estimación global del ciclo de trabajo desde 54MHz a 6GHz. Para cada frecuencia medida, el ciclo de trabajo se calcula como el cociente entre el número de muestras de la densidad espectral de potencia (DEP) correspondientes a canales ocupados (tiempo en el que los canales son usados por sus usuarios) y el número total de muestras de la DEP capturadas durante el periodo de medida. Para cada frecuencia, esta métrica representa la fracción de tiempo durante la cual el canal permanece ocupado. Para una determinada banda, el ciclo de trabajo promedio se calcula como la media aritmética de los ciclos de trabajo obtenidos para las diversas frecuencias medidas dentro de dicha banda [6, 149]. En la Figura 3-2, se hace evidente que el espectro está siendo subutilizado.




Figura 3-2: Ciclo de trabajo del rango completo de espectro medido durante la Campaña [149].

La Figura 3-3 resume las estadísticas de ocupación promedio de espectro, en función de los servicios de cada banda, utilizando los equipos de medida de la Tabla 3-1. Los resultados obtenidos muestran que algunas bandas de espectro están sujetas a moderados niveles de utilización (espectro que es usado; pero no durante todo el tiempo); mientras que algunas otras exhiben usos escasos y, en algunos casos, prácticamente no se usan [149].




Figura 3-3: Porcentaje del ciclo de trabajo de acuerdo a los servicios ofrecidos en las bandas medidas [149].

3.2 Análisis de bandas móviles

En la Figura 3-4 se presentan los resultados de las potencias medidas para tres canales del enlace de bajada, durante una semana. Los canales se escogieron con niveles de ocupación: alto, con una frecuencia central de 828.73 MHz (canal alto); medio, con una frecuencia central de 830.13 MHz (canal medio), y bajo, con una frecuencia central de 828.93 MHz (canal bajo); respecto a los 60 canales medidos en esta banda. La configuración del analizador de espectro para esta banda fue la siguiente: RBW de 100kHz, con un tiempo de barrido de 290ms, lo que garantiza la detección de señales GSM, las cuales tienen un ancho de banda de 200kHz. Los ciclos de trabajo por día de los canales seleccionados se muestran en la Figura 3-5 y el umbral (λ) utilizado, que para este caso es de -89dBm, se obtiene a partir de la Ecuación (3.4), para una probabilidad de falsa alarma (P_{fa}) del 1% [152]:

$$P_{fa} = \frac{\Gamma(m, \frac{\lambda}{2})}{\Gamma(m)} \quad (3.4)$$

Donde $\Gamma(\cdot)$ y $\Gamma(\cdot, \cdot)$ son la función gamma completa e incompleta, respectivamente, y m es el producto del tiempo por el ancho de banda.




Figura 3-4: Potencias medidas para tres canales del enlace de bajada de la banda GSM.




Figura 3-5: Ciclos de trabajo de tres canales del enlace de bajada de la banda GSM.

Las Figuras 3-6, 3-7 y 3-8 presentan los histogramas correspondientes a la distribución de oportunidades en periodos de tiempo para los canales de la banda GSM; aquí se observa que dichas oportunidades tienen un comportamiento exponencial, cuyas ecuaciones aproximadas se exhiben en cada Figura. A medida que aumenta la ocupación del canal, se observa que la ocurrencia se presenta, especialmente, en los periodos de tiempo más cortos. Para los canales de ocupación baja, media y alta, los tiempos totales de oportunidades son de, aproximadamente, 84 horas, 81 horas y 78 horas, respectivamente, lo que indica relativamente baja ocupación.




Figura 3-6: Distribución de oportunidades de periodos de tiempo del canal de ocupación baja.




Figura 3-7: Distribución de oportunidades de periodos de tiempo del canal de ocupación media.




Figura 3-8: Distribución de oportunidades de periodos de tiempo del canal de ocupación alta.

A continuación se procede a analizar las series de tiempo de los canales medidos durante una semana, lo que equivale a 1'062.514 muestras. Para esto, inicialmente, se presenta la autocorrelación simple, como se observa en la Figura 3-9. Los diagramas de autocorrelación, para los tres canales, presentan una forma alternadamente positiva y negativa, decayendo lentamente a cero, y cuyos valores están por encima del intervalo de confianza, lo que indica la existencia de correlación [100].




Figura 3-9: Autocorrelación para los tres canales del enlace de bajada de la banda GSM [100].

Al analizar la estacionariedad de los canales de la Figura 3-9, se observa que la media y varianza son constantes y similares entre sí, en cada uno de los días, desde el lunes hasta el viernes, es así que para el canal de ocupación baja, la media oscila entre -96.17 y -96.01dBm, y la varianza entre 6.6 y 7.17; para el canal de ocupación media, la media oscila entre -94.97 y -94.8dBm, y la varianza entre 18.8 y 21.02; para el canal de ocupación alta, la media oscila entre -94.75 y -94.18dBm, y la varianza entre 29.36 y 31.46. Por tanto, las mediciones del fin de semana no se toman en cuenta para el entrenamiento en los modelos analizados, debido a que la media para el canal bajo se encuentra entre -96.34 y -96.24dBm, y la varianza entre 3.62 y 4.37; para el canal medio, la media se encuentra entre -95.76 y -95.35dBm, y la varianza entre 8.67 y 10.79; para el canal alto, la media se encuentra entre -95.43 y -95.34dBm, y la varianza entre 13.82 y 15.68; lo que indica que no son similares y cambian considerablemente con respecto a las mediciones de lunes a viernes.

Adicionalmente, se analiza el parámetro de auto-similitud $H = 1+a/2$, denominado parámetro de *Hurst*, el cual se utiliza como medida de dependencia a largo plazo de la serie de tiempo y, así, comprobar su posibilidad de pronóstico. Acá a es una pendiente de la línea de regresión [153]. En las Figuras 3-10, 3-11 y 3-12 se estima el parámetro de

Hurst para los canales medidos. Los tres canales tienen un alto grado de auto-similitud puesto que $H > 0.5$; no obstante, el canal de ocupación baja presenta una mejor probabilidad de pronóstico que los canales restantes, debido a que su H es más cercano a uno.




Figura 3-10: Estimación del parámetro de *Hurst* para el canal de ocupación baja.




Figura 3-11: Estimación del parámetro de *Hurst* para el canal de ocupación media.




Figura 3-12: Estimación del parámetro de *Hurst* para el canal de ocupación alta.

4. Diseño del modelo de propagación

Inicialmente, se realiza una validación de los modelos de series de tiempo a través de la confrontación, en un tiempo, de las medidas de potencia de recepción de los canales de ocupación baja, media y alta; y del resultado pronosticado por los modelos de series de tiempo. Junto a esto, se determina qué modelo es el más adecuado para el posterior desarrollo del modelo de propagación. En segundo lugar, se ajustan los modelos de propagación del Capítulo 2, a partir de las medidas obtenidas alrededor del entorno. Finalmente, se presenta la metodología para el diseño del modelo de propagación.

La evaluación de los resultados obtenidos en los pronósticos de los siguientes modelos se realiza utilizando el software Matlab®, en un computador de dos núcleos de procesamiento de 2.4GHz y 4GB de memoria RAM, y con base en las variables: tiempo de disponibilidad del canal, tiempo de ocupación del canal, tiempo de observación y análisis de los criterios de error (error porcentual absoluto medio simétrico [SMAPE], error porcentual absoluto medio [MAPE] y error absoluto medio [MAE]) [154]. El tiempo de disponibilidad permite analizar la precisión, en el pronóstico, con la que los usuarios de CR podrían usar el tiempo disponible (o hueco espectral) en los canales GSM, en un sistema de CR. Asimismo, el tiempo de ocupación examina la precisión en el pronóstico del tiempo en el que los PU utilizan los canales GSM.

4.1 Análisis y validación del modelo estacional ARIMA

En la Figura 4-1, se presenta la tendencia y estacionalidad en el nivel de ocupación de los tres canales, cuya estacionalidad tiene un periodo de 24 horas, prácticamente, sin tendencia y con componentes estacionarios, lo cual hace viable el uso de un modelo SARIMA, para pronosticar el comportamiento del sistema GSM [100].

La diferencia del retardo s , que para este caso se selecciona como cinco (Δ_5), equivale al número de días de la semana en los que la señal es estacionaria [95]. Al aplicar la prueba aumentada de Dickey–Fuller [155] en las series de los tres canales, entre los días lunes y viernes, se rechaza la hipótesis nula de la raíz unitaria, lo que indica que existe estacionariedad. Con el fin de encontrar los parámetros del modelo SARIMA $(p, d, q)(P, D, Q)_s$, se calcula la autocorrelación simple y parcial para Δ_5 de los respectivos canales, como se muestra en la Figura 4-2.

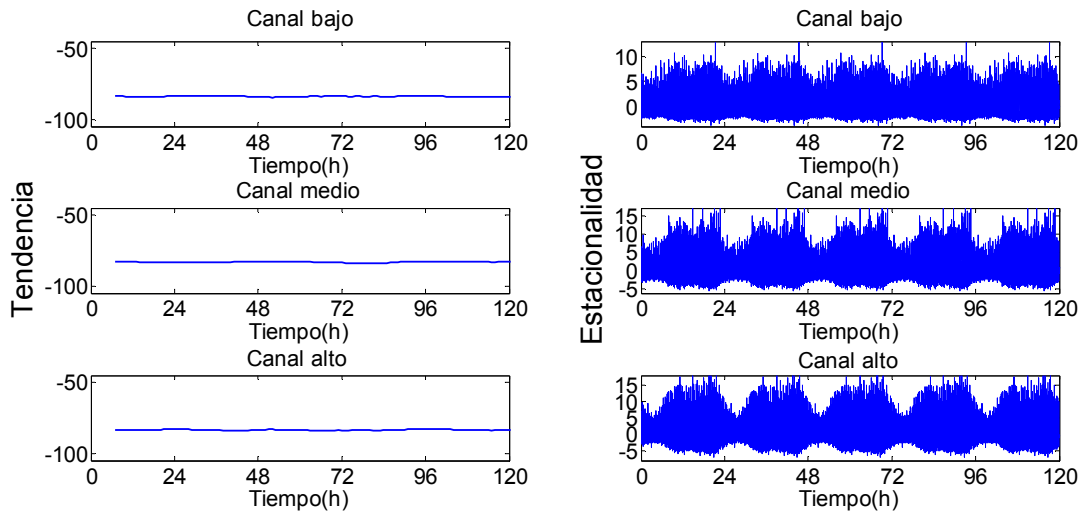


Figura 4-1: Componentes de tendencia y estacionalidad de los canales GSM [100].

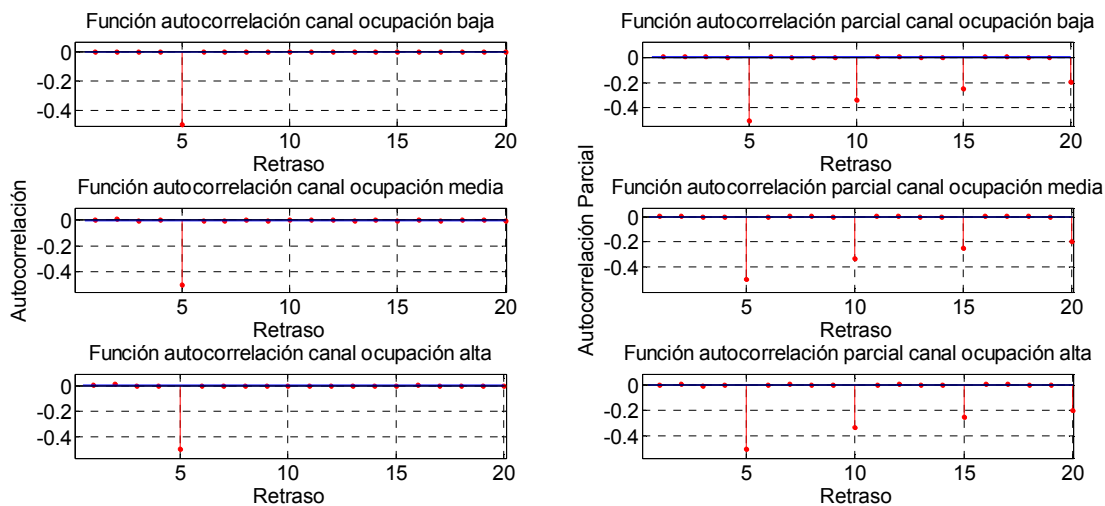


Figura 4-2: Autocorrelación simple y parcial para los canales GSM [100].

Usando la metodología de Box–Jenkins [98], la Figura 4-2 muestra que la autocorrelación parcial de Δ_5 decae a cero con un patrón estacional y cruza el nivel de confianza, inicialmente, en el retraso 5 para el lado negativo; esto sugiere que podría usarse un término AR(1) no estacional y que se podría adicionar MA(5) estacional.

A fin de evitar el sobre-estimado para pronosticar (varianza pequeña y grandes errores), se selecciona el criterio de información de Akaike (AIC) [156], con el que se evalúan las diferentes combinaciones razonables, como se observa en la Tabla 4-1. De esta manera, los modelos seleccionados son SARIMA(1,0,5)x(1,0,1)₅, SARIMA(1,0,5)x(0,0,1)₅ y SARIMA(1,0,5)x(0,0,1)₅, para los niveles de ocupación de los canales bajo, medio y alto, respectivamente; y las ecuaciones que los describen, en el mismo orden son:

$$(1 - 0.0135B)(1 - 0.55B^5)(1 - B)(1 - B^5)x_t = (1 - 0.997B^5)(1 - 0.546B^5)e_t \quad (4.1)$$

$$(1 - 0.0192B)(1 + 0.996B^5)(1 - B)(1 - B^5)x_t = (1 + 0.0085B^5)e_t \quad (4.2)$$

$$(1 - 0.0199B)(1 - 0.016B^5)(1 - B)(1 - B^5)x_t = (1 - 0.994B^5)e_t \quad (4.3)$$

Tabla 4-1: Valores AIC para diferentes modelos.

p	d	q	P	D	Q	AIC Canal ocupación baja	AIC Canal ocupación media	AIC Canal ocupación alta
1	0	5	0	0	1	-8.24	-30.6	-50.82
1	0	5	1	0	0	-8.3	-32.7	-51.7
1	1	5	0	0	1	-14.1	-46.9	-76.2
1	0	5	1	0	1	-8.19	-32.6	-50.9

La Figura 4-3 muestra la validación de los pronósticos de los modelos obtenidos a partir de las Ecuaciones (4.1), (4.2) y (4.3), contrastado con los datos medidos para las potencias del día viernes desde las 5 pm hasta las 6 pm.




Figura 4-3: Series de los canales GSM y series pronosticadas para el modelo SARIMA.

En las Figuras 4-4 y 4-5, se presentan los tiempos de disponibilidad y ocupación de los canales medidos y los pronosticados. Las precisiones promedio, obtenidas en el pronóstico de los tiempos disponibles son: 82%, 54% y 60%, y para los tiempos de ocupación equivalen a: 58%, 77% y 78%; entre los datos reales y pronosticados correspondientes a los canales de niveles de ocupación baja, media y alta, respectivamente. Adicionalmente, como es de esperarse, existe una relación inversamente proporcional entre la ocupación de canal y su tiempo de disponibilidad, y una relación directamente proporcional entre la probabilidad de ocupación y el tiempo de ocupación de los canales.




Figura 4-4: Tiempo de disponibilidad de los canales para el modelo SARIMA.




Figura 4-5: Tiempo de ocupación de los canales para el modelo SARIMA.

En la Tabla 4-2, se comparan los datos pronosticados y los medidos, con respecto a diferentes métodos para estimar el error. De los resultados de la Tabla 4-2, se puede observar que el modelo de canal de ocupación baja presenta mejor comportamiento frente al error, que los modelos de los canales de ocupación media y alta.

Tabla 4-2: Comparación de variables de error para el modelo SARIMA.

Canal	SMAPE	MAPE	MAE
Bajo	0.0170	0.0172	1.6042
Medio	0.0470	0.0466	4.2987
Alto	0.0488	0.0497	4.4195

En la Figura 4-6, se muestra la comparación del rendimiento en el pronóstico, desde uno hasta cinco días de entrenamiento del modelo SARIMA. Aquí se observa que, mientras mayor es el tiempo de observación, menor es el error de predicción; aunque no de una manera significativa. Por ejemplo, para el canal bajo, se logra una reducción del error del 2.5%, a costa de un aumento del 261% en el tiempo de observación; para el canal medio, el error disminuye 7.8%, con un incremento en el tiempo de observación de 158.6%, y para el canal alto, el error se mitiga un 7.8%, con un crecimiento del 177.1% para el tiempo de observación. El primer tiempo de observación, en los tres canales,

corresponde a un día de entrenamiento, lo que indica que, con este tiempo de entrenamiento, se alcanzan errores de predicción aceptables.




Figura 4-6: Error de predicción vs. Tiempo de observación para el modelo SARIMA.

4.2 Análisis y validación del modelo GARCH

Al analizar en detalle la gran cantidad de información adquirida, se observa la existencia de desviación estándar; por tanto, se utiliza el modelo GARCH, con el objeto de pronosticar el comportamiento de la serie medida.

Los modelos estocásticos ARIMA y SARIMA son métodos de modelamiento univariante. La principal diferencia de los anteriores modelos con el modelo GARCH es con respecto al supuesto de varianza constante.

Aunque para el modelo desarrollado se indica que existe estacionariedad en la señal original desde el día lunes hasta el día viernes, para este caso, se desarrolla la quinta diferencia porque existe un mayor grado de estacionariedad. En la Figura 4-7, se presenta la diferencia para cada canal, acá se convierten las medidas del canal a retornos por transformación logarítmica. Los retornos logarítmicos se definen como:

$$r_t = \ln \frac{P_t}{P_{t-1}} \quad (4.4)$$

Donde, P_t es el valor de la potencia en el tiempo t y P_{t-1} es el valor de la potencia en el tiempo $t-1$.




Figura 4-7: Quinta diferencia de las potencias medidas en los canales de la banda GSM.

A continuación, se presenta la prueba estadística formal para establecer la presencia de efectos ARCH en los datos y en la correlación. $H = 0$ implica que no existe una correlación significativa y $H = 1$ indica que existe una correlación significativa. En las Tablas 4-3 y 4-4 todos los valores de p muestran que la Prueba-Q *Ljung-Box-Pierce* y la prueba de ARCH, en los retrasos 10, 15 y 20, son significativos; esto demuestra la presencia de efectos ARCH.

Tabla 4-3: Prueba-Q *Ljung-Box-Pierce* de autocorrelación: (en 95% de confianza) para canales GSM.

Retraso	H	Valor de p	Prueba estadística			Valor crítico
			canal bajo	canal medio	canal alto	
10	1	0	725124	731923	731240	18.3
15	1	0	725136	731956	731266	24.99
20	1	0	725138	731996	731313	31.41

Tabla 4-4: Prueba de ARCH Engle de heterocedasticidad: (en 95% de confianza) para canales GSM.

Retraso	H	Valor de p	Prueba estadística			Valor crítico
			canal bajo	canal medio	canal alto	
10	1	0	574940	578554	576595	18.3
15	1	0	578008	581225	579079	24.99
20	1	0	578710	581829	579500	31.41

La dependencia en los datos x_1, \dots, x_n se determinó mediante el cálculo de las correlaciones. Esto se hace representando la ACF.

Si la serie de tiempo es el resultado de un fenómeno completamente aleatorio, la autocorrelación debe estar cerca de cero para todas las separaciones de los retrasos. De lo contrario, una o más de las autocorrelaciones serán significativamente diferentes de cero. Otra forma útil para examinar las dependencias de la serie es examinar la PACF, donde se elimina la dependencia de los elementos intermedios (aquellos dentro de los retrasos). En la Figura 4-8, las gráficas de ACF, PACF y ACF de los retornos al cuadrado, demuestran la existencia de correlación en los datos de ocupación de los canales.




Figura 4-8: Gráficas de correlación de los canales de la banda GSM.

A continuación, en las Tablas 4-5, 4-6 y 4-7, se procede a la evaluación y selección del modelo GARCH para cada canal.

Tabla 4-5: Comparación de modelos GARCH para el canal bajo.

Modelo	AIC	BIC	Error estándar	Logaritmo de verosimilitud	SMAPE	MAPE	MAE
GARCH(0,1)	201838	201873	7.8×10^{-4}	96127.5	0.0249	0.0253	2.3606
GARCH(1,1)	192263	192309	7.82×10^{-4}	96127.5	0.0249	0.0253	2.3604
GARCH(0,2)	192622	192649	7.8×10^{-4}	96127.5	0.0248	0.0252	2.3492
GARCH(1,2)	192265	192299	0.0016	96127.5	0.0244	0.0248	2.3075
GARCH(2,1)	191587	191621	7.33×10^{-4}	96127.5	0.0251	0.0255	2.3792
GARCH(2,2)	191581	191622	0.0034	96127.5	0.0243	0.0247	2.3060

Tabla 4-6: Comparación de modelos GARCH para el canal medio.

Modelo	AIC	BIC	Error estándar	Logaritmo de verosimilitud	SMAPE	MAPE	MAE
GARCH(0,1)	876834	876854	7.6×10^{-4}	422041	0.0374	0.0393	3.4198
GARCH(1,1)	844089	844117	6.6×10^{-4}	422041	0.0427	0.0440	3.8676
GARCH(0,2)	844984	845012	6.6×10^{-4}	422041	0.0375	0.0395	3.4385
GARCH(1,2)	844091	844125	0.0012	422041	0.0411	0.0429	3.7699
GARCH(2,1)	843470	843504	6.0×10^{-4}	422041	0.0410	0.0427	3.7531
GARCH(2,2)	843472	843513	5.0×10^{-4}	422041	0.0434	0.0452	3.9895

Tabla 4-7: Comparación de modelos GARCH para el canal alto.

Modelo	AIC	BIC	Error estándar	Logaritmo de verosimilitud	SMAPE	MAPE	MAE
GARCH(0,1)	1223114	1223135	7.8×10^{-4}	608609	0.0514	0.0542	4.6565
GARCH(1,1)	1217225	1217252	6.6×10^{-4}	608609	0.0551	0.0580	5.0138
GARCH(0,2)	1220306	1220333	6.7×10^{-4}	608609	0.0534	0.0557	4.7957
GARCH(1,2)	1217227	1217261	5.3×10^{-4}	608609	0.0566	0.0591	5.1279
GARCH(2,1)	1214308	1214343	6.5×10^{-4}	608609	0.0540	0.0570	4.9224
GARCH(2,2)	1214310	1214352	5.4×10^{-4}	608609	0.0620	0.0675	5.9397

La selección del modelo GARCH para cada canal se realiza dándole cumplimiento al criterio $\alpha_i + \beta_i < 1$ para que el modelo sea estacionario, y, adicionalmente, teniendo en cuenta los valores más cercanos a cero de MAE, MAPE y SMAPE de las Tablas 4-5, 4-6 y 4-7. Por tanto, los modelos seleccionados para el canal bajo, medio y alto son GARCH(2,2), GARCH(0,2) y GARCH(0,1), respectivamente.

En la Tabla 4-8, se estiman los parámetros para el modelo de canal bajo, GARCH(2,2), en el que se cumple $\alpha_1 + \alpha_2 + \beta_1 + \beta_2 < 1$.

Tabla 4-8: Estimación de los parámetros para el modelo de canal bajo.

Parámetro	Valor estimado	Error estándar	Valor t
μ	- 96.112	0.0019308	-49778.3308
α_0	0.003516	0.00041447	8.4833
GARCH(1)	0.098255	0.19212	0.5114
GARCH(2)	0.90062	0.19201	4.6905
ARCH(1)	0.00029573	0.00018772	1.5753
ARCH(2)	0	0.00020886	0

Por tanto, el modelo según la Tabla 4-8 es,

$$r_t = -96.112 + \epsilon_t$$

$$\sigma_t^2 = 0.003516 + 0.098255\sigma_{t-1}^2 + 0.90062\sigma_{t-2}^2 + 0.00029573\epsilon_{t-1}^2 \quad (4.5)$$

Para el canal medio, GARCH(0,2), se estiman los valores del modelo presentados en la Tabla 4-9.

Tabla 4-9: Estimación de los parámetros para el modelo de canal medio.

Parámetro	Valor estimado	Error estándar	Valor t
μ	-95.061	0.0024331	-39069.8019
α_0	5	0.012924	386.8834
ARCH(1)	0.085692	0.0010392	82.4572
ARCH(2)	0.088298	0.0010582	83.4378

Por tanto, se tiene:

$$\begin{aligned} r_t &= -95.061 + \epsilon_t \\ \sigma_t^2 &= 5 + 0.085692\epsilon_{t-1}^2 + 0.088298\epsilon_{t-2}^2 \end{aligned} \quad (4.6)$$

Para el canal alto, GARCH(0,1), se obtienen los siguientes parámetros, mostrados en la Tabla 4-10.

Tabla 4-10: Estimación de los parámetros para el modelo de canal alto.

Parámetro	Valor estimado	Error estándar	Valor t
μ	-94.585	0.0026236	-36051.8702
α_0	5	0.015341	325.9324
ARCH(1)	0.86058	0.0044771	192.2169

Entonces, el modelo es:

$$\begin{aligned} r_t &= -94.585 + \epsilon_t \\ \sigma_t^2 &= 5 + 0.86058\epsilon_{t-1}^2 \end{aligned} \quad (4.7)$$

El análisis del modelo ARCH-GARCH se basa en la evaluación de los residuos estandarizados [110]. Uno de los supuestos del modelo GARCH es que, para un buen modelo, los residuos deben seguir un proceso de ruido blanco, es decir, se espera que los residuos sean aleatorios, independientes e idénticamente distribuidos, siguiendo una distribución normal. La Figura 4-9 presenta la relación entre las innovaciones (residuales) derivadas del modelo ajustado, las correspondientes desviaciones estándar condicionales y los retornos. En la Figura 4-9, se observa que tanto las innovaciones como los retornos exhiben variaciones.

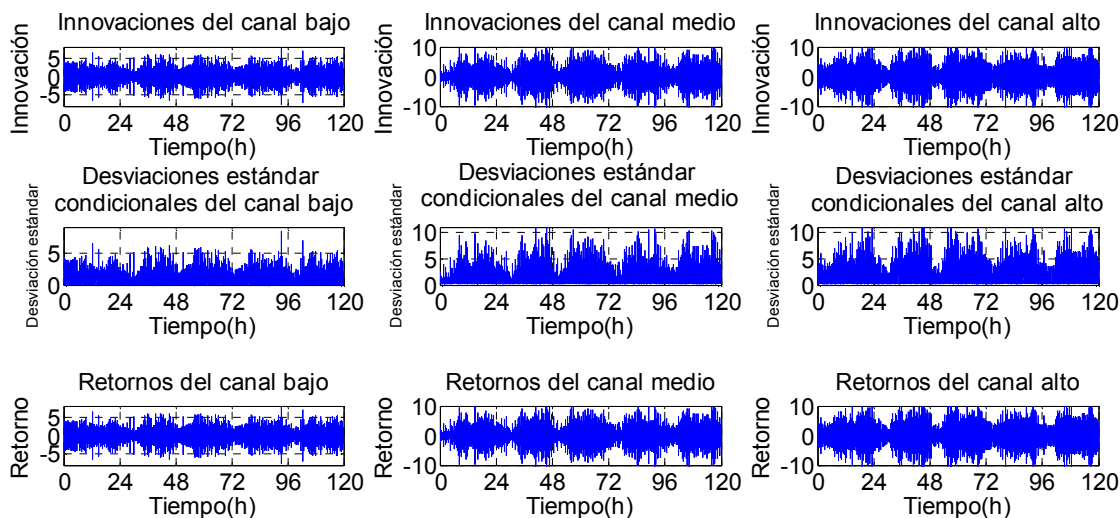


Figura 4-9: Innovaciones, desviaciones estándar condicionales y retornos de los canales GSM.

La Figura 4-10, corresponde a la autocorrelación de las innovaciones estandarizadas al cuadrado, en la que no se observa correlación.




Figura 4-10: Autocorrelación de las innovaciones estandarizadas al cuadrado de los canales GSM.

En las Tablas 4-11 y 4-12 se presentan los resultados de la prueba-Q *Ljung-Box-Pierce* y la prueba de ARCH para el análisis posterior, usando innovaciones estandarizadas. Estas pruebas indican que no existe presencia de correlación ni de efectos ARCH.

Tabla 4-11: Prueba-Q Ljung-Box-Pierce en innovaciones estandarizadas para canales GSM.

Retraso	H	Valor de p			Prueba estadística			Valor crítico
		canal bajo	canal medio	canal alto	canal bajo	canal medio	canal alto	
10	0	0.424	0.402	0.701	25787	26701	33455	18.3
15	0	0.7014	0.6883	0.8236	26447	28617	37143	24.99
20	0	0.947	0.876	0.9355	26945	30313	40772	31.41

Tabla 4-12: Prueba de ARCH Engle en innovaciones estandarizadas para canales GSM.

Retraso	H	Valor de p			Prueba estadística			Valor crítico
		canal bajo	canal medio	canal alto	canal bajo	canal medio	canal alto	
10	0	0.539	0.479	0.6212	26930	27093	33757	18.3
15	0	0.776	0.7144	0.7697	27432	28443	36248	24.99
20	0	0.908	0.863	0.8841	27792	29443	38240	31.41

La comprobación de la normalidad se realiza mediante el análisis del histograma de los residuos y el gráfico de probabilidad normal, como se observa en la Figura 4-11. El histograma de los tres canales muestra que los residuos siguen una distribución normal. Asimismo, en el gráfico de probabilidad se observa que la normalidad de los residuos es una distribución normal, ya que la mayor parte de los datos se encuentra a lo largo de la línea recta.

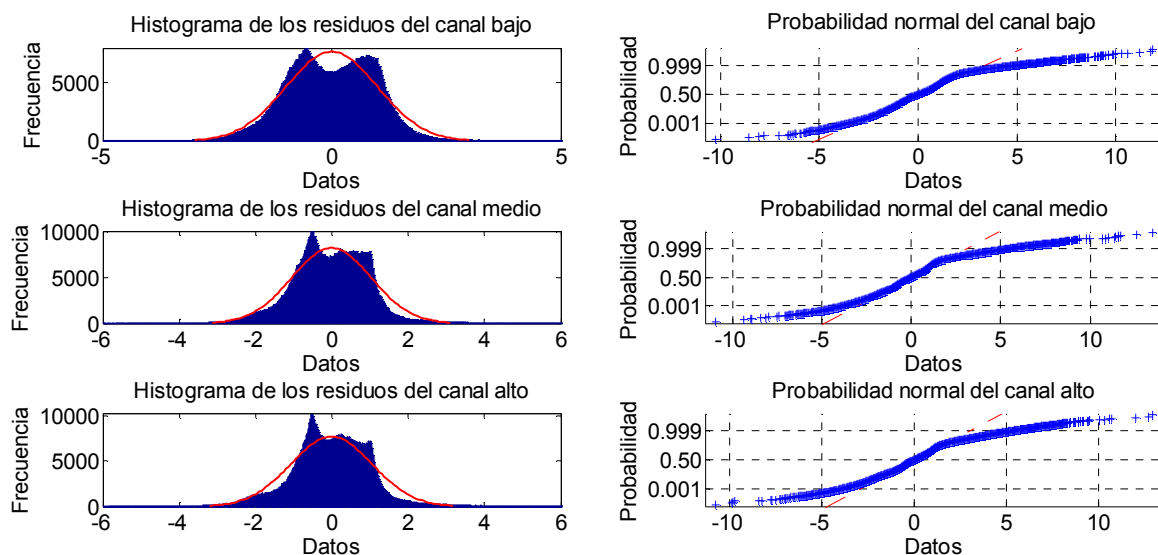


Figura 4-11: Histograma de residuos y probabilidad normal para los canales GSM.

La Figura 4-12 presenta la validación de los pronósticos de los modelos obtenidos para el día viernes, desde las 5 pm hasta las 6 pm, a partir de las Ecuaciones (4.5), (4.6) y (4.7); lo que es contrastado con los datos medidos.




Figura 4-12: Series de los canales GSM y series pronosticadas con el modelo GARCH.

En las Figuras 4-13 y 4-14, se presentan los tiempos de disponibilidad y ocupación de los canales medidos y los pronosticados. Las precisiones promedio obtenidas en el pronóstico de los tiempos de ocupación son: 44%, 46.6% y 44.2%, y para los tiempos de disponibilidad equivalen a: 31%, 30% y 43%; entre los datos reales y pronosticados

correspondientes a los canales de niveles de ocupación baja, media y alta, respectivamente.




Figura 4-13: Tiempo de ocupación de los canales para el modelo GARCH.




Figura 4-14: Tiempo de disponibilidad de los canales para el modelo GARCH.

En la Figura 4-15, se muestra la comparación del rendimiento en el pronóstico, desde uno hasta cinco días de entrenamiento del modelo GARCH. Aquí, se observa que para el canal bajo, el error de predicción permanece prácticamente constante para los diferentes tiempos de observación; para el canal medio, se alcanza a reducir el error máximo en un 5.7% a costa de un aumento en el tiempo de observación del 72.7%; y para el canal alto, la reducción máxima del error es del 15.3%, con un incremento en el tiempo de

observación del 128.5%. Al igual que con el modelo SARIMA, basta con un día de entrenamiento del modelo GARCH para lograr errores de predicción tolerables en los tres canales GSM.




Figura 4-15: Error de Predicción vs. Tiempo de observación para el modelo GARCH.

4.3 Análisis y validación del modelo de Markov

El diseño del algoritmo HMM utilizado para pronosticar la potencia recibida en los canales GSM se basa en el diagrama de flujo propuesto en la Figura 4-16. Dado que las estimaciones de los parámetros se calculan a través del algoritmo EM, entonces, se escogen los valores iniciales para la implementación. Estos valores deben ser razonables para que el algoritmo obtenga los máximos locales. Los valores iniciales para el algoritmo se encuentran mediante el empleo de un método de mínimos cuadrados en los primeros puntos de los datos. Las estimaciones de los parámetros resultantes se usan como aproximaciones para los valores iniciales de los parámetros α , γ y ξ ; estos son: $\alpha = 1.53$, $\gamma = -96.3192$ y $\xi = 3.2551$; $\alpha = 0.09$, $\gamma = -81.8678$ y $\xi = 6.7551$; $\alpha = 0.05$, $\gamma = -94.8265$ y $\xi = 8.7551$, para los canales de ocupación baja, media y alta, respectivamente. Los valores iniciales para la matriz de probabilidad de transición Π se establecen en $1/N$, donde N indica el número de estados, como se define en la implementación.

El valor a predecir de la potencia de recepción se calcula por:

$$E[y_{k+1}|F_k] = E[\alpha(x_k)y_k + \gamma(x_k) + \xi(x_k)w_{k+1}|F_k] = \langle \alpha, \Pi \hat{x}_k \rangle y_k + \langle \gamma, \Pi \hat{x}_k \rangle \quad (4.8)$$

Donde $\hat{x}_k = E[x_k|F_k]$. La Figura 4-17 muestra la serie de tiempo de los valores medidos y valida los resultados pronosticados para una hora (viernes de 5 a 6 pm), generados por un modelo de 3 estados. El número de estados se seleccionó a partir del menor AIC; para este caso, es el de 3 estados, comparado con respecto a los valores de 2 y 4 estados. En la Figura 4-18, se presenta la evolución de los parámetros α , γ , ξ y la probabilidad de transición después de 1440, 1654 y 1879 pasos; para los canales de ocupación baja, media y alta, respectivamente.

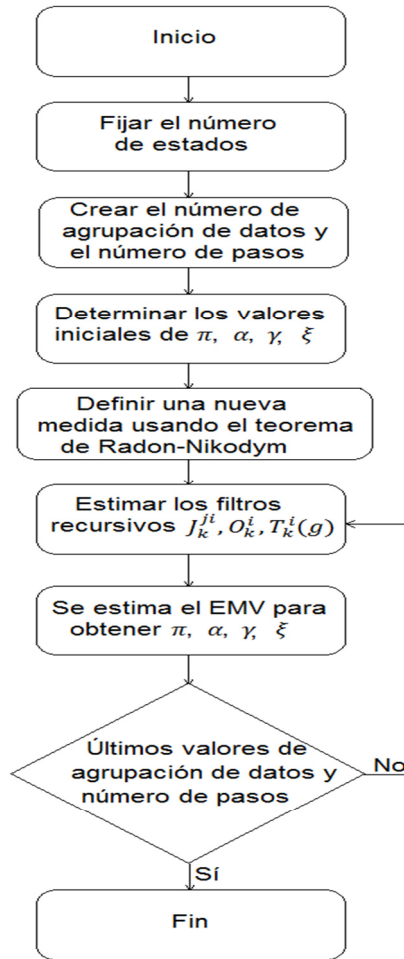


Figura 4-16: Diagrama de flujo de modelo oculto de Markov.





Figura 4-17: Series de tiempo medida y pronosticada para los canales GSM con el modelo de Markov.



a)

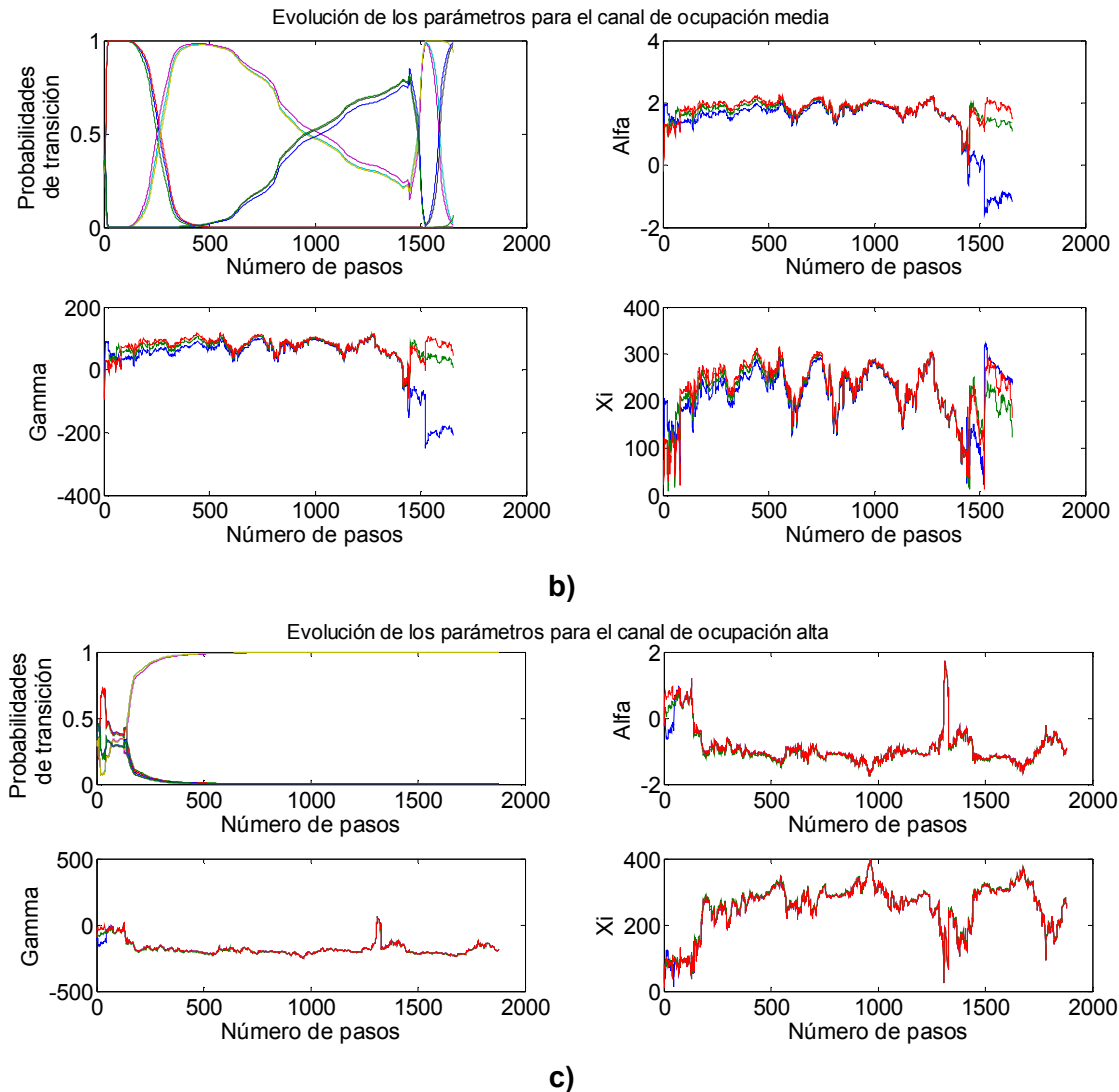


Figura 4-18: Evolución de los parámetros α , γ , ξ y la probabilidad de transición para los canales GSM. a) Ocupación baja, b) Ocupación media, c) Ocupación alta.

Las Figuras 4-19 y 4-20 presentan los tiempos de disponibilidad y ocupación de los canales medidos y los pronosticados para los modelos de Markov. Las precisiones promedio, obtenidas en el pronóstico de los tiempos de disponibilidad, son: 31%, 41% y 32%, y para los tiempos de ocupación, equivalen a: 79%, 46% y 60%; entre los datos reales y pronosticados correspondientes a los canales de niveles de ocupación baja, media y alta, respectivamente.




Figura 4-19: Tiempo de disponibilidad de canales para el modelo de Markov.




Figura 4-20: Tiempo de ocupación de canales para el modelo de Markov.

En la Tabla 4-13, se presentan los errores entre los datos reales y los pronosticados para los modelos de Markov. El modelo de canal de ocupación media presenta menores errores que los modelos de los canales de ocupación baja y alta.

Tabla 4-13: Comparación de variables de error para canales GSM con base en el modelo de Markov.

Canal	SMAPE	MAPE	MAE
Bajo	0.0231	0.0227	2.1336
Medio	0.02	0.0189	1.6016
Alto	0.1201	0.1117	4.3067

En la Figura 4-21 se evalúa el rendimiento frente al pronóstico, desde uno hasta cinco días de entrenamiento del modelo de Markov. Para el canal medio, el error de predicción tiene muy poca variación para los diferentes tiempos de observación; para el canal bajo, se alcanza a reducir el error máximo en un 16.6% a costa de un aumento en el tiempo de observación del 349%; y para el canal alto, la reducción máxima del error es del 27%, con un incremento en el tiempo de observación del 391%. Para el canal medio, se recomienda usar un día de entrenamiento; para el canal bajo, es suficiente con el uso de dos días de entrenamiento, y para el canal alto, se sugiere emplear cinco días de entrenamiento; ello, con el fin de obtener errores aceptables.




Figura 4-21: Error de predicción de vs. Tiempo de observación para el modelo de Markov.

4.4 Análisis y validación del modelo EMD-SVR

El modelo EMD-SVR presenta un mayor consumo en tiempo de procesamiento que los otros modelos presentados, lo que conlleva a que los recursos de la máquina con la que se realizó la simulación sean insuficientes para un entrenamiento con el total de los datos de entrada (lunes a viernes); por tanto, este modelo se entrena con 152.000 datos, el cual corresponde, aproximadamente, a un día de mediciones; además, se pronostican los siguientes 6.351 valores que equivalen a la hora del día viernes de 5 a 6 pm; luego, se validan los resultados. El procedimiento para el desarrollo del modelo EMD-SVR, presentado en la Figura 2-2, se puede resumir en los siguientes pasos:

1. Se ejecuta el algoritmo EMD. En este paso, se obtienen 10 datos de la serie de tiempo (9 IMF y 1 residuo), como se muestra en las Figuras 4-22, 4-23 y 4-24.




Figura 4-22: Resultados de los datos EMD para el canal de ocupación baja.




Figura 4-23: Resultados de los datos EMD para el canal de ocupación media.




Figura 4-24: Resultados de los datos EMD para el canal de ocupación alta.

2. Se realiza el procesamiento normalizado de las series de datos de cada ramificación, con el fin de mejorar la precisión del modelado.
3. Se dividen los datos en dos grupos. Los primeros 152.000 datos se utilizan como conjunto de datos de entrenamiento y los últimos 6.350 datos son el conjunto de datos de prueba.
4. Se crea el modelo SVR para cada serie de la ramificación, con base en el conjunto de datos de entrenamiento; en seguida, se reconstruyen y pronostican los datos correspondientes a 1 hora, tal y como se presenta en la Figura 4-25.




Figura 4-25: Series de tiempo medida y pronosticada de los canales GSM para el modelo EMD-SVR.

Los tiempos de disponibilidad y ocupación de los canales medidos y pronosticados a través del modelo EMD-SVR se presentan en las Figuras 4-26 y 4-27. Las precisiones promedio obtenidas en el pronóstico de los tiempos de ocupación son: 81%, 80% y 62%, y para los tiempos de disponibilidad equivalen a: 30%, 42% y 44%; entre los datos reales y pronosticados correspondientes a los canales de niveles de ocupación baja, media y alta, respectivamente.




Figura 4-26: Tiempo de disponibilidad de canales para el modelo EMD-SVR.




Figura 4-27: Tiempo de ocupación de canales para el modelo EMD-SVR.

En la Tabla 4-14, se presentan los errores entre los datos reales y los pronosticados para el modelo EMD-SVR. El modelo de canal de ocupación baja presenta una cuantía menor de los errores, con respecto a los modelos de los canales de ocupación media y alta.

Tabla 4-14: Comparación de variables de error para canales GSM con base en el modelo EMD-SVR.

Canal	SMAPE	MAPE	MAE
Bajo	0.0681	0.0556	5.296
Medio	0.0654	0.0598	5.411
Alto	0.0991	0.0890	8.022

En la Figura 4-28, se evalúa el rendimiento frente al pronóstico, con 6h, 12h, 18h y 24h de entrenamiento del modelo EMD-SVR. Aquí se observa poca variación del error para los tres canales, por ejemplo: para el canal bajo, en el escenario más optimista, el error de predicción se disminuye un 12.1%, a expensas de un aumento en el tiempo de observación del 24.8%; para el canal medio, se alcanza a reducir el error máximo en un 10.15%, a costa de un aumento en el tiempo de observación del 26.43%, y para el canal alto, la reducción máxima del error es del 4.7%, con un incremento en el tiempo de observación del 35%. Con 6h de entrenamiento del modelo EMD-SVR se consiguen errores de predicción adecuados en los tres canales GSM.




Figura 4-28: Error de predicción vs. Tiempo de observación para el modelo EMD-SVR.

4.5 Análisis y validación del modelo neuronal wavelet

La señal de entrada al modelo, correspondiente a la potencia recibida de los canales GSM, se descompone usando la wavelet madre, *Discrete Meyer* (dmey), que presentó un menor error al ser comparada con las *wavelets* madre *Daubechies*, *Coiflets* y *Symlets* [157]. El resultado son 2 niveles que contienen, en total, 4 coeficientes.

La red neuronal wavelet multi-capas de propagación hacia atrás desarrollada es mostrada en la Figura 4-29, y es expresada como:

$$f[n] = g \sum_{i=1}^n \left[\frac{1}{\sqrt{M}} \sum_k W_\phi[j_0, k] \phi_{j_0, k}[n] + \frac{1}{\sqrt{M}} \sum_{j=j_0}^{\infty} \sum_k W_\psi[j, k] \psi_{j, k}[n] \right] \quad (4.9)$$

Donde g es la función de activación de la red neuronal, que para este caso contiene: 2 entradas, 2 salidas y 2 capas ocultas. La red fue entrenada con los 714.952 datos de la señal de entrada (medidas de lunes a viernes) y se aumentó el número de patrones de entrenamiento hasta que el error disminuyó y se hizo relativamente constante; esto se alcanzó para 1.000 patrones de entrenamiento. Finalmente, la salida de la red neuronal es reconstruida usando un análisis wavelet para obtener la potencia pronosticada.

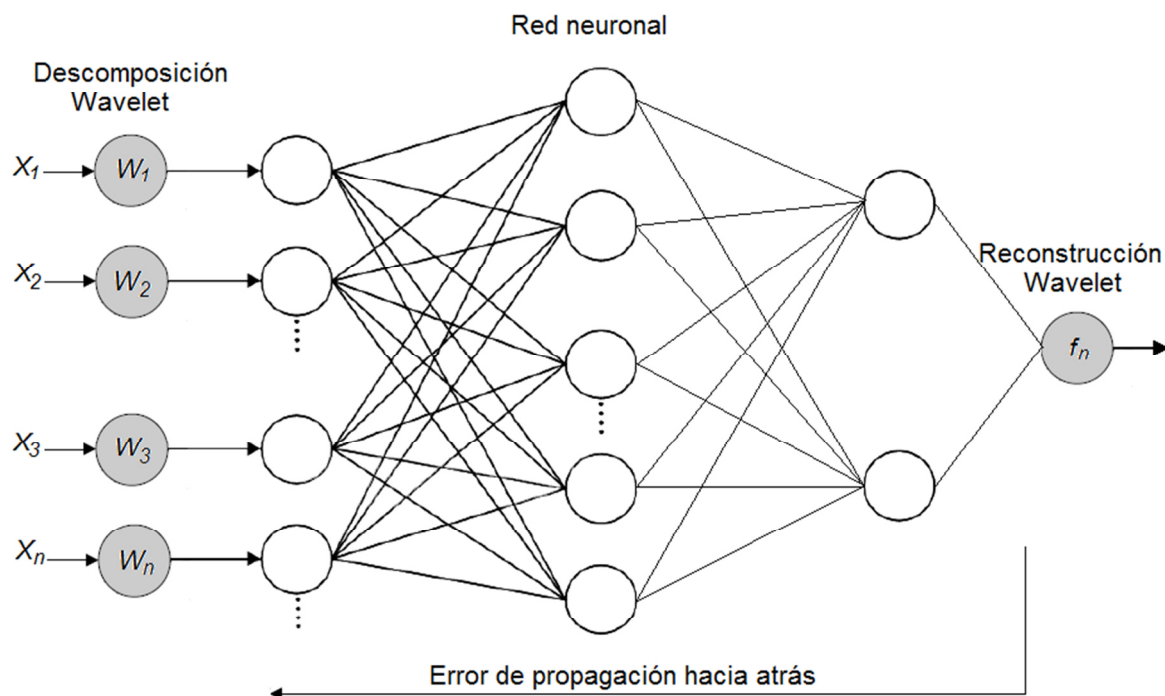


Figura 4-29: Red neuronal wavelet.

La Figura 4-30 valida los valores de potencia pronosticados, con respecto a los medidos durante una hora, que corresponden al día viernes de 5 a 6 pm.




Figura 4-30: Series de tiempo medida y pronosticada para los canales GSM con el modelo neuronal wavelet.

Los tiempos de disponibilidad y ocupación de los canales medidos y pronosticados, a través del modelo neuronal wavelet, se presentan en las Figuras 4-31 y 4-32. Las precisiones promedio obtenidas en el pronóstico de los tiempos de ocupación son: 100%, 95.1% y 99.9%, y para los tiempos de disponibilidad equivalen a: 100%, 97% y 99.8%; entre los datos reales y pronosticados correspondientes a los canales de niveles de ocupación baja, media y alta, respectivamente.




Figura 4-31: Tiempo de ocupación de canales para el modelo neuronal wavelet.




Figura 4-32: Tiempo de disponibilidad de canales para el modelo neuronal wavelet.

En la Tabla 4-15, se presentan los errores entre los datos reales y los pronosticados para los modelos neuronal wavelet. El modelo de canal de ocupación baja presenta los menores errores con respecto a los modelos de los canales de ocupación media y alta.

Tabla 4-15: Comparación de variables de error para canales GSM con base en el modelo neuronal wavelet.

Canal	SMAPE	MAPE	MAE
Bajo	0.0017	0.00089	0.0866
Medio	0.0020	0.0011	0.1
Alto	0.0019	0.0010	0.1005

En la Figura 4-33, se evalúa el rendimiento frente al pronóstico, desde uno hasta cinco días de entrenamiento del modelo neuronal wavelet. El error en el canal alto se reduce en un total de 1.75%, en detrimento de un 31.24% en el tiempo de observación; para el canal medio, el error, en total, se disminuye en un 3.29%, a costa de un 23.8% en el tiempo de observación; y para el canal bajo, el total del error es minimizado en un 5.45% en menoscabo de un 47.5% en el tiempo de observación.

Al validar el modelo neuronal wavelet, se presentó mayor precisión en el pronóstico de las potencias de recepción, con respecto a los cuatro modelos restantes, tal y como se demostró a través de las variables evaluadas. La disminución del error del modelo neuronal wavelet llega a ser de 10 a 80 veces, en relación con los otros modelos, sin contemplar un mejoramiento en el error de predicción mayor al 99%. Por estas razones, el modelo neuronal wavelet se selecciona para ser usado en el posterior diseño de los modelos de propagación.




Figura 4-33: Error de predicción vs. Tiempo de observación para el modelo neuronal wavelet.

Para completar el análisis del entrenamiento, se calcula el error cuadrático medio, correspondiente al promedio del cuadrado de las desviaciones estándares de los valores estimados con respecto a los originales. En las Tablas 4-16, 4-17 y 4-18 se exhibe el error cuadrático medio en el pronóstico de las potencias de recepción, para el modelo neuronal wavelet, con una cantidad de datos de entrenamiento de hasta cinco días. Estos resultados y la Figura 4-33 justifican que un día de entrenamiento en el modelo neuronal wavelet es suficiente para obtener un error admisible. Además, el canal de ocupación baja presenta el menor error y la mayor precisión en los pronósticos de los tiempos de disponibilidad y ocupación del canal, tal como se concluyó en el análisis del parámetro de *Hurst*.

Tabla 4-16: Resultado de error cuadrático medio para el canal bajo, con diferentes días de entrenamiento del modelo neuronal wavelet.

Días de entrenamiento	Error cuadrático medio	Tiempo de procesamiento
1	2.3784	24.19 s
2	2.3402	27.21 s
3	2.3015	31.39 s
4	2.2851	34.92 s
5	2.2659	35.69 s

Tabla 4-17: Resultado de error cuadrático medio para el canal medio con diferentes días de entrenamiento del modelo neuronal wavelet.

Días de entrenamiento	Error cuadrático medio	Tiempo de procesamiento
1	4.661	28.19 s
2	4.6133	29.55 s
3	4.5878	30.85 s
4	4.5549	34.27 s
5	4.5213	34.9 s

Tabla 4-18: Resultado de error cuadrático medio para el canal alto con diferentes días de entrenamiento del modelo neuronal wavelet.

Días de entrenamiento	Error cuadrático medio	Tiempo de procesamiento
1	2.9262	26.47 s
2	2.8558	28.68 s
3	2.8110	29.64 s
4	2.7604	31.87 s
5	2.7339	34.76 s

El pronóstico de la potencia recibida, realizado durante esta sección, no solo es importante en la determinación del estado de un canal; sino porque permite omitir la detección de algún canal cuando se pronostica que estará ocupado, lo que reduce el tiempo de detección y el consumo de energía.

4.6 Ajuste a modelos de propagación

En la Figura 4-34 se presenta el entorno alrededor de la celda de la BTS en el que se realizaron las medidas descritas en el capítulo anterior para el norte de la ciudad de Bogotá D.C. La semana de mediciones se desarrolló en el punto A. Los cinco puntos de medida restantes corresponden a sitios de cobertura de la celda, los cuales se encuentran a diferentes distancias de la BTS, para evaluar y ajustar los modelos de propagación descritos en la sección 2.1. La duración de las medidas en estos cinco puntos fue aproximadamente de una hora. El entorno es llano y está conformado, en su mayoría, por concentración de edificios; aunque también hay zonas verdes, con algunos árboles, como se observa en el punto de medida D.



Figura 4-34: Puntos de medida en la zona norte de la ciudad de Bogotá D.C.

En la Tabla 4-19 se presentan los parámetros del Tx y Rx para ser utilizados en los modelos de propagación.

Tabla 4-19: Parámetros de la BTS y el analizador.

Parámetro	Valor
Potencia de transmisión BTS (P_{Tx})	26 dBm
Altura BTS	26 m
Ganancia antena BTS (G_{BTS})	16.5 dBi
Pérdidas combinador BTS (L_{co})	4 dB
Pérdidas cable BTS (L_c)	4 dB
Ganancia antena analizador (G_{An})	3 dBi
Pérdidas cable analizador (L_{ca})	0.72 dB
Ganancia Amplificador de bajo ruido (G_{LNA})	11 dB
Altura analizador	1.5 m
Frecuencia de transmisión canal bajo	828.73 MHz
Frecuencia de transmisión canal medio	830.13 MHz
Frecuencia de transmisión canal alto	828.93 MHz

A continuación, se evalúan los modelos de propagación con la información de la Tabla 4-19, para, luego, ajustarlos tomando como referencia las potencias medidas en los seis puntos de la Figura 4-34.

4.6.1 Ajuste al modelo Okumura-Hata

Haciendo uso de la Ecuación (2.1), se obtienen las pérdidas de propagación teóricas promedio (\bar{L}) del modelo O-H para cada punto de medida, como se observa en la Tabla 4-20.

Tabla 4-20: Pérdidas de propagación del modelo O-H para los puntos de medida de la Figura 4-34.

Punto	\bar{L} canal bajo (dB)	\bar{L} canal medio (dB)	\bar{L} canal alto (dB)
F(58m)	82.279	82.298	82.282
C(152m)	97.188	97.207	97.191
D(226m)	103.326	103.345	103.329
B(287m)	107.024	107.043	107.026
E(290m)	107.184	107.204	107.187
A(328m)	109.09	109.109	109.093

Con los resultados de la Tabla 4-20 y los parámetros de la Tabla 4-19, se obtiene la potencia de recepción promedio ($\overline{P_{RX}}$) teórica [77]:

$$\overline{P_{RX}} = P_{TX} + G_{BTS} + G_{An} + G_{LNA} - \bar{L} - L_c - L_{co} - L_{ca} \quad (4.10)$$

En las Figuras 4-35, 4-36 y 4-37, se presenta la $\overline{P_{RX}}$ hallada a través de la Ecuación (4.10) para el modelo O-H, en comparación con el rango de la potencia de recepción medida con sus respectivos valores promedio. En estas Figuras, existe una diferencia apreciable entre los datos teóricos respecto a los medidos.




Figura 4-35: Potencia de recepción teórica y medida para el modelo O-H del canal bajo.




Figura 4-36: Potencia de recepción teórica y medida para el modelo O-H del canal medio.




Figura 4-37: Potencia de recepción teórica y medida para el modelo O-H del canal alto.

Con el fin de aumentar la precisión del modelo de propagación de O-H, se usa el método de mínimos cuadrados [158], para ajustar los resultados teóricos a los valores promedio medidos. A partir de esto, se obtienen las siguientes ecuaciones ajustadas para los canales bajo, medio y alto, de manera respectiva:

$$\begin{aligned} \bar{L}_{Bajo}(dB) = & 79.3407 + 26.16 \log f_c - 13.82 \log hte - a(h_{re}) \\ & + (17.4938 - 6.55 \log hte) \log d \end{aligned} \quad (4.11)$$



$$\begin{aligned} \bar{L}_{Medio}(dB) = & 76.5997 + 26.16 \log f_c - 13.82 \log hte - a(h_{re}) \\ & + (15.6501 - 6.55 \log hte) \log d \end{aligned} \quad (4.12)$$

$$\begin{aligned} \bar{L}_{Alto}(dB) = & 78.2616 + 26.16 \log f_c - 13.82 \log hte - a(h_{re}) \\ & + (19.5356 - 6.55 \log hte) \log d \end{aligned} \quad (4.13)$$

En las Figuras 4-38, 4-39 y 4-40 se presenta la potencia de recepción del modelo O-H ajustado con las Ecuaciones (4.11), (4.12) y (4.13), respecto al promedio de la potencia de recepción medida. En las Figuras, se aprecia una aproximación entre los valores medidos y el modelo ajustado, cuyo error cuadrático medio se observa en la Tabla 4-21 para cada canal.

Tabla 4-21: Error cuadrático medio del modelo O-H ajustado.

Error Cuadrático Medio		
canal bajo	canal medio	canal alto
1.4315	0.6093	1.2688

**Figura 4-38:** Potencia de recepción ajustada y medida para el modelo O-H del canal bajo.**Figura 4-39:** Potencia de recepción ajustada y medida para el modelo O-H del canal medio.




Figura 4-40: Potencia de recepción ajustada y medida para el modelo O-H del canal alto.

4.6.2 Ajuste al modelo Cost 231 Walfisch-Ikegami

A partir de la Ecuación (2.5) se obtienen las \bar{L} del modelo C231-W-I para cada punto de medida, como se observa en la Tabla 4-22.

Tabla 4-22: Pérdidas de propagación del modelo C231-W-I para los puntos de medida de la Figura 4-34.

Punto	\bar{L} canal bajo (dB)	\bar{L} canal medio (dB)	\bar{L} canal alto (dB)
F(58m)	82.615	82.642	82.62
C(152m)	93.403	93.43	93.409
D(226m)	98.838	98.863	98.841
B(287m)	102.288	102.316	102.294
E(290m)	102.4438	102.469	102.447
A(328m)	104.667	104.292	104.27

En las Figuras 4-41, 4-42 y 4-43 se presenta la $\overline{P_{RX}}$ hallada a través de la Ecuación (4.10), para el modelo C231-W-I, con respecto al rango de la potencia de recepción medida con sus respectivos valores promedio. También, en las Figuras de este modelo, se muestra un error considerable entre los datos teóricos respecto a los medidos.




Figura 4-41: Potencia de recepción teórica y medida para el modelo C231-W-I del canal bajo.




Figura 4-42: Potencia de recepción teórica y medida para el modelo C231-W-I del canal medio.




Figura 4-43: Potencia de recepción teórica y medida para el modelo C231-W-I del canal alto.

Para ajustar los valores teóricos a los medidos en el modelo C231-W-I, se hace uso del método de mínimo cuadrados [158]. Entonces se obtiene:

1. Para el canal bajo, la modificación de las ecuaciones (2.6), (2.8) y (2.12), da como resultado, de manera respectiva:

$$L_0(dB) = 47.3213 - 195.146 \log d + 20 \log f_c \quad (4.14)$$

$$L_{ori} = -10 + 0.0254\varphi \text{ para } 0^\circ \leq \varphi < 35^\circ \quad (4.15)$$

$$K_d = 203.3658 \text{ para } h_b > h_{Roof} \quad (4.16)$$

Con las Ecuaciones (4.14), (4.15) y (4.16) se construye la Ecuación (2.5) del modelo C231-W-I y se grafica la Figura 4-44, en la que también se incluye el valor promedio de la potencia medida.




Figura 4-44: Potencia de recepción ajustada y medida para el modelo C231-W-I del canal bajo.

2. El resultado en la modificación de las Ecuaciones (2.6), (2.8) y (2.12), para el canal medio, es:

$$L_0(dB) = 44.3848 + 111.444 \log d + 20 \log f_c \quad (4.17)$$

$$L_{ori} = -10 + 0.0215\varphi \text{ para } 0^\circ \leq \varphi < 35^\circ \quad (4.18)$$

$$K_d = -105.2172 \text{ para } h_b > h_{Roof} \quad (4.19)$$

Estas nuevas Ecuaciones se incluyen en la Ecuación (2.5) del modelo C231-W-I y se obtiene la Figura 4-45, junto al valor promedio de la potencia medida.




Figura 4-45: Potencia de recepción ajustada y medida para el modelo C231-W-I del canal medio.

3. De la misma forma, para el canal alto, la modificación de las Ecuaciones (2.6), (2.8) y (2.12), conlleva a:

$$L_0(dB) = 47.1435 - 612.156 \log d + 20 \log f_c \quad (4.20)$$

$$L_{ori} = -10 + 0.0162\varphi \text{ para } 0^\circ \leq \varphi < 35^\circ \quad (4.21)$$

$$K_d = 622.4238 \text{ para } h_b > h_{Roof} \quad (4.22)$$

Estas tres Ecuaciones son contenidas en la Ecuación (2.5) del modelo C231-W-I para elaborar la Figura 4-46, la cual contiene, además, el valor promedio de la potencia medida.




Figura 4-46: Potencia de recepción ajustada y medida para el modelo C231-W-I del canal alto.

En las Figuras 4-44, 4-45 y 4-46 se observa una reducción en el error, entre los valores medidos y el modelo ajustado, al contrastarse con las Figuras 4-41, 4-42 y 4-43. En la Tabla 4-23 se presentan el error cuadrático medio para cada canal.

Tabla 4-23: Error cuadrático medio del modelo C231-W-I ajustado.

Error Cuadrático Medio		
canal bajo	canal medio	canal alto
1.4170	0.6186	1.5456

4.6.3 Ajuste al modelo interino de la Universidad de Stanford

En la Tabla 4-24, se muestran las \bar{L} para el modelo SUI en los seis puntos medidos, haciendo uso de la Ecuación (2.14) y del terreno tipo B de la Tabla 2-1.

Tabla 4-24: Pérdidas de propagación del modelo SUI para los puntos de medida de la Figura 4-34.

Punto	\bar{L} canal bajo (dB)	\bar{L} canal medio (dB)	\bar{L} canal alto (dB)
F(58m)	69.791	69.805	69.793
C(152m)	88.572	88.587	88.574
D(226m)	96.304	96.319	96.306
B(287m)	100.962	100.977	100.965
E(290m)	101.165	101.18	101.167
A(328m)	103.566	103.58	103.568

Para el hallazgo de la $\overline{P_{RX}}$, se hace uso de la Ecuación (4.10), cuyos resultados se presentan en las Figuras 4-47, 4-48 y 4-49. Estos resultados son confrontados con el rango de los valores de potencias medidas y sus correspondientes datos promedio, los cuales indican la existencia de un notable error.




Figura 4-47: Potencia de recepción teórica y medida para el modelo SUI del canal bajo.




Figura 4-48: Potencia de recepción teórica y medida para el modelo SUI del canal medio.




Figura 4-49: Potencia de recepción teórica y medida para el modelo SUI del canal alto.

Con el propósito de minimizar el error de las Figuras 4-47, 4-48 y 4-49, se ajusta el modelo SUI empleando el método de mínimos cuadrados [158]. De este modo, se obtienen las siguientes Ecuaciones para cada canal:

$$\bar{L}_{Bajo}(dB) = A + 1.831 \gamma \log \left[\frac{d}{d_0} \right] + S + 47.4982 \quad (4.23)$$

$$\bar{L}_{Medio}(dB) = A + 1.389 \gamma \log \left[\frac{d}{d_0} \right] + S + 46.6648 \quad (4.24)$$

$$\bar{L}_{Alto}(dB) = A + 2.287 \gamma \log \left[\frac{d}{d_0} \right] + S + 44.3754 \quad (4.25)$$

Con las Ecuaciones (4.23), (4.24) y (4.25) se halla la $\overline{P_{RX}}$ para cada canal; esta se grafica en las Figuras 4-50, 4-51 y 4-52, la cual, a su vez, contiene la potencia de recepción promedio medida.




Figura 4-50: Potencia de recepción ajustada y medida para el modelo SUI del canal bajo.




Figura 4-51: Potencia de recepción ajustada y medida para el modelo SUI del canal medio.




Figura 4-52: Potencia de recepción ajustada y medida para el modelo SUI del canal alto.

Finalmente, se exhibe el error cuadrático medio entre los datos medidos y ajustados en la Tabla 4-25, donde se vislumbra un reducido error.

Tabla 4-25: Error cuadrático medio del modelo SUI ajustado.

Error Cuadrático Medio		
canal bajo	canal medio	canal alto
1.4315	0.6078	1.2688

Al comparar los errores cuadráticos medios de las Tablas 4-21, 4-23 y 4-25, se observan valores relativamente cercanos entre cada uno de los modelos de propagación. Es así que los modelos O-H, C231-W-I y SUI son adecuados para aproximar los valores promedio de las potencias recibidas en los puntos medidos; sin embargo, el modelo de mayor precisión para el canal bajo es el C231-W-I, para el canal medio es el SUI y para el canal alto son el SUI o el O-H. A pesar de ello, la ventaja de los modelos O-H y SUI es que son más sencillos de ajustar, ya que poseen menos variables que el modelo C231-W-I.

4.7 Metodología de diseño del modelo de propagación

Ahora, se describe la metodología usada para diseñar el modelo de propagación, y la ecuación general para pronosticar la potencia de recepción con el modelo neuronal wavelet y los modelos de propagación descritos y ajustados anteriormente.

Entonces, el procedimiento general para obtener el modelo de propagación en un entorno desconocido es el siguiente:

1. Realizar mediciones.

En este paso, se toman las mediciones del canal y/o canales del espectro radioeléctrico variantes, en función del tiempo durante un día, con base en el método descrito en la sección 3.1.

2. Seleccionar el modelo de propagación a gran escala.

Se escoge el modelo de propagación apropiado al entorno urbano, según las variables que utiliza y el resultado de las mediciones en diferentes puntos.

3. Ajustar modelo de propagación.

El modelo de propagación seleccionado en el paso 2 se ajusta. Por ejemplo, con el método de mínimos cuadrados, en función de los valores promedio de las mediciones.

4. Entrenar modelo neuronal wavelet.

Con las mediciones realizadas por un tiempo mínimo de 24 horas se entrena el modelo neuronal wavelet diseñado.

5. Integrar modelos.

Extrapolar el modelo de propagación ajustado al modelo neuronal wavelet, integrando las pérdidas de propagación promedio con las pérdidas instantáneas.

6. Pronosticar la potencia de recepción.

A lo largo del entorno urbano analizado, se pronostica la potencia de recepción durante un tiempo determinado, con base en el modelo de propagación compuesto en el paso 5.

Por consiguiente, el modelo de propagación, que tiene en cuenta tanto las pérdidas instantáneas como las pérdidas promedio de propagación, se puede escribir a nivel general de la siguiente forma:

$$L = \Delta L + \bar{L} \quad (4.26)$$

Donde $\Delta L = f(f[n]) \big|_{f[n] = \Delta P_{RX}}$ son las pérdidas de propagación instantáneas en función de la potencia de recepción obtenida en la Ecuación (4.9), y \bar{L} son las pérdidas de propagación promedio, obtenidas a partir del ajuste de cada modelo realizado en las secciones 4.6.1, 4.6.2 y 4.6.3. Por tanto, al combinar la Ecuación (4.9) con la Ecuación (4.10), se obtiene la potencia de recepción en función de los modelos de propagación descritos anteriormente:

$$P_{RX} = g \sum_{i=1}^n \left[\frac{1}{\sqrt{M}} \sum_k W_\phi[j_0, k] \Phi_{j_0, k}[n] + \frac{1}{\sqrt{M}} \sum_{j=j_0}^{\infty} \sum_k W_\psi[j, k] \psi_{j, k}[n] \right] + \bar{P}_{RX} \quad (4.27)$$

Donde $\bar{P}_{RX} = f(\bar{L})$. En la Figura 4-53 se representa la Ecuación (4.27).

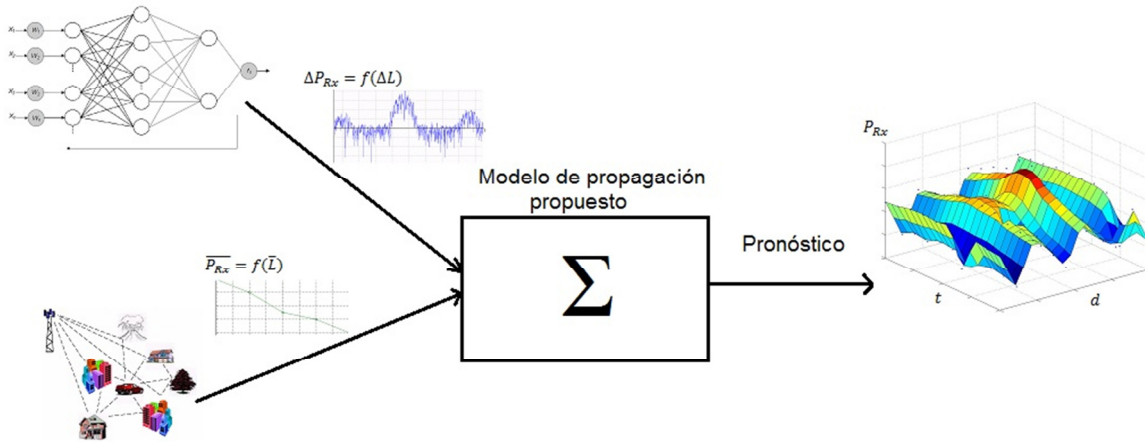


Figura 4-53: Esquema del modelo de propagación propuesto.

5.Resultados y discusión

En este Capítulo, se presentan y discuten los resultados del modelo de propagación, diseñado en el Capítulo anterior, para los diferentes niveles de ocupación de los canales. En la Figura 5-1, se exhibe un ejemplo en el que existe aplicación del modelo de propagación diseñado; aquí, el usuario de CR percibe la potencia de una BTS primaria y se puede desplazar a través de la cobertura de la celda, como lo indica el sentido de las flechas. El usuario de CR puede pronosticar el nivel de potencia que recibirá por la BTS primaria a diferentes distancias y teniendo en cuenta las pérdidas de propagación del entorno.

La evaluación de los modelos se realiza para el pronóstico, hasta en una hora, de la potencia de recepción, con una distancia máxima de 328 m. Asimismo, se muestra el ciclo de trabajo para cada modelo sobre el entorno analizado.




Figura 5-1: Ejemplo de aplicación para el modelo de propagación diseñado.

Para los modelos O-H de canal bajo, medio y alto, las ecuaciones de la potencia de recepción, de manera respectiva, son:

$$P_{RX\ O-H\ Bajo} = g \sum_{i=1}^n \left[\frac{1}{\sqrt{M}} \sum_k W_\phi[j_0, k] \Phi_{j_0, k}[n] + \frac{1}{\sqrt{M}} \sum_{j=j_0}^{\infty} \sum_k W_\psi[j, k] \psi_{j, k}[n] \right] + f[79.3407 + 26.16 \log f_c - 13.82 \log hte - a(h_{re}) + (17.4938 - 6.55 \log hte) \log d] \quad (5.1)$$

$$P_{RX\ O-H\ Medio} = g \sum_{i=1}^n \left[\frac{1}{\sqrt{M}} \sum_k W_\phi[j_0, k] \Phi_{j_0, k}[n] + \frac{1}{\sqrt{M}} \sum_{j=j_0}^{\infty} \sum_k W_\psi[j, k] \psi_{j, k}[n] \right] + f[76.5997 + 26.16 \log f_c - 13.82 \log hte - a(h_{re}) + (15.6501 - 6.55 \log hte) \log d] \quad (5.2)$$

$$P_{RX\ O-H\ Alto} = g \sum_{i=1}^n \left[\frac{1}{\sqrt{M}} \sum_k W_\phi[j_0, k] \Phi_{j_0, k}[n] + \frac{1}{\sqrt{M}} \sum_{j=j_0}^{\infty} \sum_k W_\psi[j, k] \psi_{j, k}[n] \right] + f[78.2616 + 26.16 \log f_c - 13.82 \log hte - a(h_{re}) + (19.5356 - 6.55 \log hte) \log d] \quad (5.3)$$

En las Figuras 5-2, 5-3 y 5-4, se muestran las gráficas de la Ecuaciones (5.1), (5.2) y (5.3), correspondientemente.




Figura 5-2: Potencia de recepción para el modelo O-H del canal bajo.




Figura 5-3: Potencia de recepción para el modelo O-H del canal medio.




Figura 5-4: Potencia de recepción para el modelo O-H del canal alto.

Las ecuaciones de los canales bajo, medio y alto, para el pronóstico de la potencia de recepción, con base en el modelo C231-W-I, corresponden a:

$$\begin{aligned}
 P_{RX \text{ C231-W-I Bajo}} = & g \sum_{i=1}^n \left[\frac{1}{\sqrt{M}} \sum_k W_\phi[j_0, k] \phi_{j_0, k}[n] + \frac{1}{\sqrt{M}} \sum_{j=j_0}^{\infty} \sum_k W_\psi[j, k] \psi_{j, k}[n] \right] + \\
 & f[47.3213 - 195.146 \log d + 20 \log f_c - 16.9 - 10 \log w + 10 \log f_c + 20 \log \Delta h_m + L_{ori} + \\
 & L_{bsh} + K_a + K_d \log d + K_f \log f_c - 9 \log b] \quad (5.4)
 \end{aligned}$$

$$P_{RX \text{ C231-W-I Medio}} = g \sum_{i=1}^n \left[\frac{1}{\sqrt{M}} \sum_k W_\phi[j_0, k] \Phi_{j_0, k}[n] + \frac{1}{\sqrt{M}} \sum_{j=j_0}^\infty \sum_k W_\psi[j, k] \psi_{j, k}[n] \right] + f[44.3848 + 111.444 \log d + 20 \log f_c - 16.9 - 10 \log w + 10 \log f_c + 20 \log \Delta h_m + L_{ori} + L_{bsh} + K_a + K_d \log d + K_f \log f_c - 9 \log b] \quad (5.5)$$

$$P_{RX \text{ C231-W-I Alto}} = g \sum_{i=1}^n \left[\frac{1}{\sqrt{M}} \sum_k W_\phi[j_0, k] \Phi_{j_0, k}[n] + \frac{1}{\sqrt{M}} \sum_{j=j_0}^\infty \sum_k W_\psi[j, k] \psi_{j, k}[n] \right] + f[47.1435 - 612.156 \log d + 20 \log f_c - 16.9 - 10 \log w + 10 \log f_c + 20 \log \Delta h_m + L_{ori} + L_{bsh} + K_a + K_d \log d + K_f \log f_c - 9 \log b] \quad (5.6)$$

Los resultados de las Ecuaciones (5.4), (5.5) y (5.6), se representan en las Figuras 5-5, 5-6 y 5-7.




Figura 5-5: Potencia de recepción para el modelo C231-W-I del canal bajo.




Figura 5-6: Potencia de recepción para el modelo C231-W-I del canal medio.




Figura 5-7: Potencia de recepción para el modelo C231-W-I del canal alto.

Finalmente, para el modelo SUI, las ecuaciones que pronostican la potencia de recepción, para los canales bajo, medio y alto, son:

$$P_{RX\ SUI\ Bajo} = g \sum_{i=1}^n \left[\frac{1}{\sqrt{M}} \sum_k W_{\phi}[j_0, k] \Phi_{j_0, k}[n] + \frac{1}{\sqrt{M}} \sum_{j=j_0}^{\infty} \sum_k W_{\psi}[j, k] \psi_{j, k}[n] \right] + f \left[A + 1.831 \gamma \log \left[\frac{d}{d_0} \right] + S + 47.4982 \right] \quad (5.7)$$

$$P_{RX\ SUI\ Medio} = g \sum_{i=1}^n \left[\frac{1}{\sqrt{M}} \sum_k W_\phi[j_0, k] \Phi_{j_0, k}[n] + \frac{1}{\sqrt{M}} \sum_{j=j_0}^{\infty} \sum_k W_\psi[j, k] \psi_{j, k}[n] \right] + f \left[A + 1.389 \gamma \log \left[\frac{d}{d_0} \right] + S + 46.6648 \right] \quad (5.8)$$

$$P_{RX\ SUI\ Alto} = g \sum_{i=1}^n \left[\frac{1}{\sqrt{M}} \sum_k W_\phi[j_0, k] \Phi_{j_0, k}[n] + \frac{1}{\sqrt{M}} \sum_{j=j_0}^{\infty} \sum_k W_\psi[j, k] \psi_{j, k}[n] \right] + f \left[A + 2.287 \gamma \log \left[\frac{d}{d_0} \right] + S + 44.3754 \right] \quad (5.9)$$

En las Figuras 5-8, 5-9 y 5-10, las Ecuaciones (5.7), (5.8) y (5.9) son interpretadas.




Figura 5-8: Potencia de recepción para el modelo SUI del canal bajo.




Figura 5-9: Potencia de recepción para el modelo SUI del canal medio.




Figura 5-10: Potencia de recepción para el modelo SUI del canal alto.

Desde la Figura 5-2 hasta la 5-10, se identifican las oportunidades espectrales (color naranja) que serían percibidas y aprovechadas por parte de los usuarios de CR; aunque para ser más precisos se depende del umbral seleccionado. Estas son obtenidas del pronóstico de una hora de potencia con base en la información histórica de un día.

A nivel general, para los tres modelos de propagación, el canal de mayor ocupación pronostica los mayores niveles de potencia recibida, al ser comparado con los canales de niveles de ocupación baja y media. En las Figuras anteriores, el nivel de potencia tiene la tendencia de disminuir a medida que aumenta la distancia, según las pérdidas halladas para cada modelo.

En el ejemplo de la Figura 5-1, para analizar los modelos de propagación, se realiza el pronóstico de la potencia desde el usuario de CR, haciendo un símil con el analizador de espectro en el que se efectuaron las mediciones; sin embargo, esto depende de la arquitectura de CR desplegada en el entorno.

Debido a que el procesador y el consumo de energía son más limitados en el equipo del usuario de CR, se recomienda el uso de una arquitectura con infraestructura donde el pronóstico se realice desde la BTS de CR, la cual es provista con un mejor procesador que el del usuario de CR y sin limitaciones en el consumo de energía. No obstante, existe un tiempo entre la captura de datos en el entorno y el procesamiento, el cual agrega un

retraso en la respuesta que no debe ser ignorado; empero, el pronóstico ayuda a reducir el impacto negativo del retraso en la respuesta. En la Figura 5-11 se presenta una arquitectura con infraestructura [2].

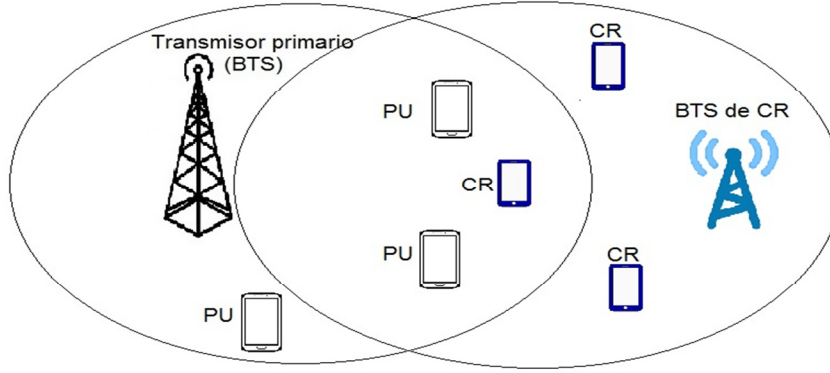


Figura 5-11: Arquitectura de CR con infraestructura.

Para un sistema de CR, el modelo desarrollado en la banda GSM, puede contribuir a mejorar el uso de la eficiencia espectral, puesto que permitiría, a los usuarios de CR, compartir los canales y evitar las colisiones con los PU en las oportunidades encontradas.

5.1 Ciclo de trabajo

El pronóstico del ciclo de trabajo se encuentra a partir de la Ecuación (5.10) [18, 159]:

$$\psi = (1 - \sum_{k=1}^K \alpha_k) P_{fa} + \sum_{k=1}^K \alpha_k Q \left(\frac{Q^{-1}(P_{fa}) \sigma_N - \gamma_k}{\sigma_{Sk}} \right) \quad (5.10)$$

Donde $K > 0$ representa el número de niveles de potencia de transmisión, los cuales pueden estar presentes en el canal; para este caso, en las medidas del punto A de la Figura 4-34 existe una sola potencia de transmisión. $0 < \alpha_k \leq 1$ es el factor de actividad del k -ésimo nivel de potencia, esto se obtiene del valor promedio de uso de cada canal analizado en la Figura 3-4. P_{fa} es la probabilidad de falsa alarma objetivo, considerada para la selección del umbral de decisión de la energía, en este ejercicio, es de 1%. $\gamma_k = P_{RXk} - P_N$ es la relación entre la señal y el ruido, que resulta del k -ésimo nivel de potencia de transmisión promedio. σ_{Sk} y σ_N son la desviación estándar en decibelios de los k -ésimos niveles de potencia de la señal y del ruido respectivamente, estos valores se

obtuvieron, experimentalmente, con el analizador de espectro y se presentan en la Tabla 5-1. $Q(\cdot)$ es la función gaussiana Q y $Q^{-1}(\cdot)$ es la inversa de $Q(\cdot)$.

P_{RXk} es la potencia recibida por el usuario, la cual ya ha sido encontrada para cada modelo. Mientras P_N , representa el piso de ruido del terminal de CR, creado a partir de la suma de todas las fuentes de ruido en el receptor (incluyendo el ruido térmico). Este se puede expresar como:

$$P_N(dBm) = -174 \frac{dBm}{Hz} + 10 \log B (Hz) + NF (dB) \quad (5.11)$$

Donde -174 dBm/Hz es la densidad espectral de potencia de ruido térmico en $290^\circ K$, B es el ancho de banda del canal detectado y NF es la figura de ruido total del receptor. El NF del amplificador de bajo ruido es 4dB, con una ganancia de 11dB; las pérdidas del cable son 0.72dB. La NF del analizador es 16dB para la configuración realizada. Por tanto, la NF total se halla a partir del factor de ruido total (F_T) [160]:

$$F_T = F_{ca} + \frac{F_{LNA}-1}{G_{ca}} + \frac{F_{An}-1}{G_{ca}G_{LNA}} = 3.266 \quad (5.12)$$

F_{ca} es el factor de ruido del cable, F_{LNA} es el factor de ruido del amplificador de bajo ruido, F_{An} es el factor de ruido del analizador de espectro, G_{ca} es la ganancia del cable y G_{LNA} es la ganancia del amplificador de bajo ruido. Por tanto, el NF total es 5.14dB.

Tabla 5-1: Valores experimentales de σ_{Sk} y σ_N para GSM.

Banda	B(kHz)	$\sigma_{Sk}(dB)$	$\sigma_N(dB)$
GSM	200	1.816	0.8785

Los ciclos de trabajo, resultado de la Ecuación (5.10), para cada modelo de propagación con los diferentes canales y en el sector de la celda de la BTS del entorno exterior de la Figura 4-34, se presentan a continuación.




Figura 5-12: Ciclo de trabajo para el modelo de O-H del canal bajo.




Figura 5-13: Ciclo de trabajo para el modelo de O-H del canal medio.




Figura 5-14: Ciclo de trabajo para el modelo de O-H del canal alto.




Figura 5-15: Ciclo de trabajo para el modelo de C231-W-I del canal bajo.




Figura 5-16: Ciclo de trabajo para el modelo de C231-W-I del canal medio.




Figura 5-17: Ciclo de trabajo para el modelo de C231-W-I del canal alto.




Figura 5-18: Ciclo de trabajo para el modelo de SUI del canal bajo.




Figura 5-19: Ciclo de trabajo para el modelo de SUI del canal medio.




Figura 5-20: Ciclo de trabajo para el modelo de SUI del canal alto.

En las anteriores Figuras de los ciclos de trabajo, se observa que, debido al planteamiento usado en la Ecuación (5.10), en el escenario, existen diferentes niveles de ocupación y no solo ocupado o libre; por ejemplo, se puede encontrar que la probabilidad de ocupación del canal es baja o alta, mas no igual a cero o a uno. El modelamiento realizado es capaz de proporcionar una caracterización realista del pronóstico de la ocupación de espectro, en función del escenario de propagación considerado, el cual constituye un aspecto importante en el diseño y dimensionamiento de sistemas de CR para implementaciones reales.

En estas Figuras, se advierte que los niveles de ocupación máxima oscilan entre 0.2 y 0.3 (dependiendo del canal). Estos valores corresponden a localizaciones cerca de la BTS y son graficados con la gama de colores rojos. Los valores de ocupación van disminuyendo y, por tanto, las oportunidades espectrales para usuarios de CR aumentan, a medida que la señal se aleja de la BTS; estos se representan mediante la gama de colores azules. Lo anterior es coherente a nivel práctico y le da robustez al modelo de propagación propuesto.

En los escenarios del canal de ocupación alta, se percibe, desde la BTS, una mayor distancia de cobertura de niveles de ocupación máxima; seguido por los escenarios del canal de ocupación baja, y, después, por los escenarios del canal de ocupación media.

En el modelo C231-W-I se presentan los niveles de ocupación baja en puntos cercanos a la BTS. Esto debido a que, en estos puntos, el ángulo φ de la Ecuación (2.8) es mayor a 35° ; en consecuencia, allí, se utilizaron los valores predefinidos por el modelo, puesto que solo se ajustó en el modelo el valor de φ menor a 35° , como consecuencia de los pequeños ángulos φ , formados en los seis puntos de medida de la Figura 4-34.

6. Conclusiones y recomendaciones

6.1 Conclusiones

1. Se realizó un análisis estadístico a partir de las mediciones realizadas por una semana en un entorno urbano de la ciudad de Bogotá, donde, inicialmente, se describieron los instrumentos utilizados, así como la configuración de estos y los resultados generales de las mediciones. Luego, se seleccionaron tres canales de diferentes niveles de ocupación, correspondientes a las bandas de la tecnología móvil GSM, en los que se analizó el ciclo de trabajo, la distribución de oportunidades y la autocorrelación.

Posteriormente, se validó el pronóstico de la potencia recibida, para una hora, con los modelos SARIMA, GARCH, Markov, EMD-SVR y neuronal wavelet, con base en las variables: tiempo de disponibilidad del canal, tiempo de ocupación del canal, tiempo de observación, SMAPE, MAPE y MAE. Finalmente, se decidió que el modelo neuronal wavelet presentó mejor desempeño, frente a las variables evaluadas, que los cuatro modelos restantes y con una relativa baja complejidad computacional.

2. Se desarrolló el diseño de un modelo de propagación para tres canales: primero, a partir del ajuste de los modelos con características de propagación a gran escala O-H, C231-W-I y SUI; con las medidas realizadas en el entorno urbano. Posteriormente, dada la aproximación del ajuste con el promedio de los datos medidos, se integró cada uno de estos modelos de propagación ajustados con el modelo neuronal wavelet.
3. Se determinaron las oportunidades espectrales de los modelos de propagación diseñados, a través del pronóstico de la potencia recibida en un tiempo determinado

y del ciclo de trabajo a lo largo de un entorno urbano. Estos resultados demuestran su consistencia con el comportamiento práctico de los sistemas de comunicaciones móviles.

4. La metodología para el diseño del modelo de propagación ha propuesto un enfoque novedoso y práctico para pronosticar la ocupación del espectro, la cual sería percibida por los usuarios de CR en escenarios reales.
5. Los modelos analizados en el Capítulo 4 no solo pronostican la potencia de recepción; sino los tiempos de ocupación y disponibilidad para los canales GSM. El modelo neuronal wavelet diseñado muestra, en la Figura 4-33, que, en sistemas prácticos de CR, sería viable usar un tiempo de observación entre 25 y 29 segundos, y los datos de entrenamiento de un día, para pronosticar con precisión la potencia recibida en un usuario de CR desde una BTS primaria.
6. La importancia en el pronóstico de la potencia recibida, a través de los modelos de propagación, radica en que las señales de los PUs se describen con mayor precisión y se mejora el rendimiento en las CRs, p. e., los usuarios de CR pueden: ahorrar energía en el proceso de detección del espectro; aprovechar las oportunidades espectrales incrementando la tasa de transmisión exitosa y las oportunidades de transmisión; reducir el tiempo para encontrar un canal disponible; y ajustar los niveles de potencia de transmisión para proteger de colisiones e interferencias a los PU.
7. La mayor parte de los esquemas de pronóstico se ha basado en la determinación de huecos espectrales; mientras que este trabajo se fundamenta en el conocimiento a priori de la potencia que se recibe por parte de los canales de los PU; esto permite evitar la selección de canales ruidosos y conllevar a un mejor reparto del espectro entre los usuarios de CR, para, así, lograr parámetros de calidad de servicio superiores con menos recursos de radio.

6.2 Recomendaciones

1. Como trabajo futuro, se propone implementar y evaluar los modelos de propagación desarrollados en equipos de radio definido por software.
2. Los resultados de medición son de un usuario de CR, en donde no se consideraron problemas de desvanecimientos por sombreado o propagación multitrayectoria diferentes a los de los modelos de propagación seleccionados. Por tanto, si se presentan este tipo de desvanecimientos no considerados, se tendría una detección errónea de la señal para el resto del entorno. A partir de esto, se aconseja usar la detección cooperativa para minimizar los errores en la detección.
3. Analizar el rendimiento en la transmisión de los usuarios de CR, a partir de los diferentes niveles de potencia recibida por parte de los PU.
4. Se sugiere tener varios equipos para medir las potencias en diferentes localizaciones del entorno durante un mismo tiempo, y, así, verificar el rendimiento de los modelos desarrollados.

Bibliografía

- [1] Haykin S., "Cognitive radio: brain-empowered wireless communications," *IEEE Journal on Selected Areas in Communications*, vol. 23, no. 2, pp. 201–220, 2005.
- [2] Akyildiz I., *et al.*, "NeXt generation / dynamic spectrum access / cognitive radio wireless networks: A survey," *Computer Networks Journal*, vol. 50, pp. 2127-2159, 2006.
- [3] Rocke S. and Wyglinski A. M., "Geo-statistical analysis of wireless spectrum occupancy using extreme value theory," in *Conference on Communications, Computers and Signal Processing*, Victoria, 2011, pp. 753-758.
- [4] Taher T. M., *et al.*, "Long-term spectral occupancy findings in Chicago," in *IEEE Symposium on New Frontiers in Dynamic Spectrum Access Networks*, Aachen, 2011, pp. 100-107.
- [5] Sanders F. H., *Broadband spectrum survey at Los Angeles, California*. U.S. Dept. of Commerce National Telecommunications and Information Administration: Boulder, Colo., 1997.
- [6] Lopez M. and Casadevall F., "Methodological aspects of spectrum occupancy evaluation in the context of cognitive radio," *European Transactions on Telecommunications*, vol. 21, no. 8, pp. 680-693, 2010.
- [7] Wellens M. and Mahonen P., "Lessons learned from an extensive spectrum occupancy measurement campaign and a stochastic duty cycle model," *Mob. Netw. Appl.*, vol. 15, no. 3, pp. 461-474, 2010.
- [8] Patil K., *et al.*, "Spectrum occupancy statistics in the context of cognitive radio," in *International Symposium on Wireless Personal Multimedia Communications*, Brest, 2011, pp. 1-5.
- [9] Chen D., *et al.*, "Mining spectrum usage data: a large-scale spectrum measurement study," in *International Conference on Mobile Computing and Networking*, Beijing, 2009, pp. 13-24.
- [10] Chiang R. I. C., Rowe G. B., and Sowerby K. W., "A Quantitative Analysis of Spectral Occupancy Measurements for Cognitive Radio," in *Vehicular Technology Conference*, Dublin, 2007, pp. 3016-3020.
- [11] Mehdawi M., *et al.*, "Spectrum occupancy measurements and lessons learned in the context of cognitive radio," in *Telecommunications Forum Telfor*, Belgrade, 2015, pp. 196-199.
- [12] Al-Hourani A., *et al.*, "Spectrum occupancy measurements for different urban environments," in *European Conference on Networks and Communications*, Paris, 2015, pp. 97-102.
- [13] Pedraza L., Forero F., and Paez I., "Metropolitan Spectrum Survey in Bogota Colombia," in *IEEE International Conference on Advanced Information Networking and Applications Workshops*, Barcelona, 2013, pp. 548-553.
- [14] Marcus M. J., "Spectrum Policy for Radio Spectrum Access," *Proceedings of the IEEE*, vol. 100, no. Special Centennial Issue, pp. 1685-1691, 2012.

- [15] FCC, "Spectrum policy task force report," *ET Docket No.02-155*, 2002.
- [16] MINTIC, "Propuesta política de espectro radioeléctrico 2015 - 2018," ed. Colombia: Agencia Nacional del Espectro, 2015.
- [17] Antón C., *et al.*, "Radio y Redes Cognitivas," *eMOV White Paper*, pp. 1-17, 2010.
- [18] Lopez M. and Casadevall F., "Statistical Prediction of Spectrum Occupancy Perception in Dynamic Spectrum Access Networks," in *IEEE International Conference on Communications*, Kyoto, 2011, pp. 1-6.
- [19] Okumura Y., *et al.*, "Field strength and its variability in UHF and VHF land-mobile radio service," *Review of the Electrical Communication Laboratory*, vol. 16, no. 9, pp. 825-873, 1968.
- [20] Turin G. L., *et al.*, "A statistical model of urban multipath propagation," *IEEE Transactions on Vehicular Technology*, vol. 21, no. 1, pp. 1-9, 1972.
- [21] Hata M., "Empirical formula for propagation loss in land mobile radio services," *IEEE Transactions on Vehicular Technology*, vol. 29, no. 3, pp. 317-325, 1980.
- [22] Walfisch J. and Bertoni H. L., "A theoretical model of UHF propagation in urban environments," *IEEE Transactions on Antennas and Propagation*, vol. 36, no. 12, pp. 1788-1796, 1988.
- [23] Har D., Watson A. M., and Chadney A. G., "Comment on diffraction loss of rooftop-to-street in COST 231-Walfisch-Ikegami model," *IEEE Transactions on Vehicular Technology*, vol. 48, no. 5, pp. 1451-1452, 1999.
- [24] Sarkar T. K., *et al.*, "A survey of various propagation models for mobile communication," *IEEE Antennas and Propagation Magazine*, vol. 45, no. 3, pp. 51-82, 2003.
- [25] Stocker K. E., Gschwendtner B. E., and Landstorfer F. M., "Neural network approach to prediction of terrestrial wave propagation for mobile radio," *IEEE Proceedings H - Microwaves, Antennas and Propagation*, vol. 140, no. 4, pp. 315-320, 1993.
- [26] Sotiroidis S. P., *et al.*, "Application of a Composite Differential Evolution Algorithm in Optimal Neural Network Design for Propagation Path-Loss Prediction in Mobile Communication Systems," *IEEE Antennas and Wireless Propagation Letters*, vol. 12, pp. 364-367, 2013.
- [27] Ostlin E., Zepernick H. J., and Suzuki H., "Macrocell Path-Loss Prediction Using Artificial Neural Networks," *IEEE Transactions on Vehicular Technology*, vol. 59, no. 6, pp. 2735-2747, 2010.
- [28] Phaiboon S., Phokharatkul P., and Somkuarnpanit S., "2 to 16 GHz Microwave Line-of-Sight Path Loss Prediction on Urban streets by Fuzzy Logic Models," in *Conference TENCON*, Melbourne, 2005, pp. 1-4.
- [29] Slattery K. and Skinner H., *Platform Interference in Wireless Systems Models, Measurement, and Mitigation*, 1st ed. Oxford: Elsevier, 2008.
- [30] Akyildiz I., *et al.*, "A Survey on Spectrum Management in Cognitive Radio Networks," *IEEE Communications Magazine*, vol. 46, no. 4, pp. 40-48, 2008.
- [31] P. Steenkiste, *et al.*, "Future Directions in Cognitive Radio Network Research," *NSF Workshop Report*, 2009.
- [32] Nokia, "Optimising spectrum utilisation towards 2020," 2014.
- [33] Fette B., "Fourteen Years of Cognitive Radio Development," in *IEEE Military Communications Conference*, San Diego, 2013, pp. 1166-1175.
- [34] Marinho J. and Monteiro E., "Cognitive radio: survey on communication protocols, spectrum decision issues, and future research directions," *Wirel. Netw.*, vol. 18, no. 2, pp. 147-164, 2012.

- [35] Hossain E., Niyato D., and Kim D. I., "Evolution and future trends of research in cognitive radio: a contemporary survey," *Wireless Communications and Mobile Computing*, vol. 15, no. 11, pp. 1530-1564, 2015.
- [36] Chu T., "On the performance assessment of advanced cognitive radio networks," Doctoral thesis, Department of Communication Systems, Blekinge Institute of Technology, Sweden, 2015.
- [37] Lingjie D., Jianwei H., and Biying S., "Investment and Pricing with Spectrum Uncertainty: A Cognitive Operator's Perspective," *IEEE Transactions on Mobile Computing*, vol. 10, no. 11, pp. 1590-1604, 2011.
- [38] "ET Docket 02-135 Spectrum Policy Task Force," Society of Broadcast Engineers, Indianapolis, 2002.
- [39] Mitola J., "Cognitive radio for flexible mobile multimedia communication," in *Mobile Multimedia Communications*, San Diego, 1999, pp. 3-10.
- [40] "ET Docket 03-222 Notice of Proposed Rule Making and Order," Federal Communications Commission, Washington, 2003.
- [41] Lee W. Y., "Spectrum Management in Cognitive Radio Wireless Networks," Thesis for the Degree Doctor of Philosophy in the School of Electrical and Computer Engineer, Georgia Institute of Technology, Atlanta, 2009.
- [42] Jondral F., "Software-Defined Radio - Basic and Evolution to Cognitive Radio," *EURASIP Journal on Wireless Communication and Networking*, vol. 5, no. 3, pp. 275-283, 2005.
- [43] Mitola J., "Cognitive Radio Architecture Evolution," *Proceedings of the IEEE*, vol. 97, no. 4, pp. 626-641, 2009.
- [44] FCC, "Notice of proposed rule making, unlicensed operation in the TV broadcast bands," *FCC 04-186*, 2004.
- [45] Marcus M. J., "Unlicensed cognitive sharing of TV spectrum: the controversy at the Federal Communications Commission," *IEEE Communications Magazine*, vol. 43, no. 5, pp. 24-25, 2005.
- [46] Youping Z., et al., "Applying Radio Environment Maps to Cognitive Wireless Regional Area Networks," in *IEEE International Symposium on New Frontiers in Dynamic Spectrum Access Networks*, Dublin, 2007, pp. 115-118.
- [47] Yucek T. and Arslan H., "A survey of spectrum sensing algorithms for cognitive radio applications," *IEEE Communications Surveys & Tutorials*, vol. 11, no. 1, pp. 116-130, 2009.
- [48] Axell E., et al., "Spectrum Sensing for Cognitive Radio : State-of-the-Art and Recent Advances," *IEEE Signal Processing Magazine*, vol. 29, no. 3, pp. 101-116, 2012.
- [49] Subhedar M. and Birajdar G., "Spectrum Sensing Techniques In Cognitive Radio Networks: A Survey," *International Journal of Next-Generation Networks*, vol. 3, no. 2, pp. 37-51, 2011.
- [50] Pedraza L., Forero F., and Páez I., "Detección de espectro para radio cognitiva," *Ingeniare. Revista chilena de ingeniería*, vol. 20, no. 2, pp. 197-210, 2012.
- [51] Kyryk M., et al., "Performance comparison of cognitive radio networks spectrum sensing methods," in *International Conference on Modern Problems of Radio Engineering, Telecommunications and Computer Science*, Lviv, 2016, pp. 597-600.
- [52] Patil V. and Patil S., "A survey on spectrum sensing algorithms for cognitive radio," in *International Conference on Advances in Human Machine Interaction*, Bangalore, 2016, pp. 1-5.

- [53] Armi N., Chaeriah B., and Arshad M., "Spectrum sensing performance in cognitive radio system," in *International Conference on Information Technology, Computer, and Electrical Engineering*, Semarang, 2015, pp. 382-385.
- [54] Helif S., Abdulla R., and Kumar S., "A review of energy detection and cyclostationary sensing techniques of cognitive radio spectrum," in *IEEE Student Conference on Research and Development*, Kuala Lumpur, 2015, pp. 177-181.
- [55] Yuan Y., et al., "KNOWS: Cognitive Radio Networks Over White Spaces," in *IEEE International Symposium on New Frontiers in Dynamic Spectrum Access Networks*, Dublin, 2007, pp. 416-427.
- [56] Cabric D., Tkachenko A., and Brodersen R. W., "Spectrum Sensing Measurements of Pilot, Energy, and Collaborative Detection," in *IEEE Military Communications Conference*, Washington, 2006, pp. 1-7.
- [57] Ganesan G. and Li Y., "Cooperative spectrum sensing in cognitive radio networks," in *IEEE International Symposium on New Frontiers in Dynamic Spectrum Access Networks*, Baltimore, 2005, pp. 137-143.
- [58] Ghasemi A. and Sousa E. S., "Optimization of Spectrum Sensing for Opportunistic Spectrum Access in Cognitive Radio Networks," in *IEEE Consumer Communications and Networking Conference*, Las Vegas, 2007, pp. 1022-1026.
- [59] Datla D., et al., "Parametric Adaptive Spectrum Sensing Framework for Dynamic Spectrum Access Networks," in *IEEE International Symposium on New Frontiers in Dynamic Spectrum Access Networks*, Dublin, 2007, pp. 482-485.
- [60] Zarrin S., "Spectrum Sensing in Cognitive Radio Networks," Doctor of Philosophy, Department Electrical and Computer Engineering, University of Toronto, 2011.
- [61] Urkowitz H., "Energy detection of unknown deterministic signals," *Proceedings of the IEEE*, vol. 55, no. 4, pp. 523-531, 1967.
- [62] Ferro R., Pedraza L., and Hernández. C., "Maximización del Throughput en una red de radio cognitiva basado en la probabilidad de falsa alarma," *Tecnura*, vol. 15, no. 30, pp. 64-70, 2011.
- [63] Ramkumar B., "Automatic modulation classification for cognitive radios using cyclic feature detection," *IEEE Circuits and Systems Magazine*, vol. 9, no. 2, pp. 27-45, 2009.
- [64] Lopez M. and Casadevall F., "Spectrum occupancy in realistic scenarios and duty cycle model for cognitive radio," *Advances in Electronics and Telecommunications, Special Issue on Radio Communication Series: Recent Advances and Future Trends in Wireless Communication*, vol. 1, no. 1, pp. 26-34, 2010.
- [65] ITU, *ITU Handbook on Spectrum Monitoring*. Ginebra, 2011.
- [66] Anritsu, *User Guide Spectrum Master MS2721B, MS2723B, MS2724B*, 2009.
- [67] Win M. Z., Pinto P. C., and Shepp L. A., "A Mathematical Theory of Network Interference and Its Applications," *Proceedings of the IEEE*, vol. 97, no. 2, pp. 205-230, 2009.
- [68] Molisch A. F., Greenstein L. J., and Shafi M., "Propagation Issues for Cognitive Radio," *Proceedings of the IEEE*, vol. 97, no. 5, pp. 787-804, 2009.
- [69] Devroye N., Mitran P., and Tarokh V., "Achievable rates in cognitive radio channels," *IEEE Transactions on Information Theory*, vol. 52, no. 5, pp. 1813-1827, 2006.
- [70] Molisch A. F., *Wireless Communications*, 2nd ed. New York: Wiley, 2011.
- [71] Erceg V., et al., "An empirically based path loss model for wireless channels in suburban environments," *IEEE Journal on Selected Areas in Communications*, vol. 17, no. 7, pp. 1205-1211, 1999.

- [72] Chu T. S. and Greenstein L. J., "A quantification of link budget differences between the cellular and PCS bands," *IEEE Transactions on Vehicular Technology*, vol. 48, no. 1, pp. 60-65, 1999.
- [73] Hari K. and Bushue C., "Interim channel models for G2 MMDS fixed wireless applications," *Tech. Rep. 802.16.3c-00/49r2*, IEEE, 2000.
- [74] Erceg V., "Channel models for fixed wireless applications," *IEEE 802.16d- 3/34*, 2003.
- [75] Jakes W. C., *Microwave Mobile Communications*, 1st ed. New York: Wiley, 1974.
- [76] Goldsmith A., *Wireless Communications*, 1st ed. New York: Cambridge University Press, 2005.
- [77] Rappaport T. S., *Wireless Communications: Principles and Practice*, 2nd ed. New Jersey: Prentice-Hall, 2002.
- [78] COST231, *Urban Transmission Loss Models for Mobile Radio in the 900- and 1,800 MHz Bands: (revision 2)*: COST 231 TD(90) 119 Rev. 2, 1991.
- [79] Bertoni H. L., *et al.*, "UHF propagation prediction for wireless personal communications," *Proceedings of the IEEE*, vol. 82, no. 9, pp. 1333-1359, 1994.
- [80] Baum D., "Final report on link level and system level channel models," *Tech. Rep. IST-2003-507581*, 2005.
- [81] Nishimori K., *et al.*, "Cognitive Radio Operation under Directional Primary Interference and Practical Path Loss Models," *IEICE Transactions on Communications*, vol. E94-B, no. 5, pp. 1243-1253, 2011.
- [82] Kashiki K., *et al.*, "Location and Propagation Status Sensing of Interference Signals in Cognitive Radio," in *International Conference on Cognitive Radio Oriented Wireless Networks and Communications*, Orlando, 2007, pp. 112-117.
- [83] Celebi H., *et al.*, "Cognitive-Radio Systems for Spectrum, Location, and Environmental Awareness," *IEEE Antennas and Propagation Magazine*, vol. 52, no. 4, pp. 41-61, 2010.
- [84] Ghasemi A. and Sousa E. S., "Interference Aggregation in Spectrum-Sensing Cognitive Wireless Networks," *IEEE Journal of Selected Topics in Signal Processing*, vol. 2, no. 1, pp. 41-56, 2008.
- [85] Wimalajeewa T. and Varshney P. K., "Polarity-Coincidence-Array Based Spectrum Sensing for Multiple Antenna Cognitive Radios in the Presence of Non-Gaussian Noise," *IEEE Transactions on Wireless Communications*, vol. 10, no. 7, pp. 2362-2371, 2011.
- [86] Hanif M. F. and Smith P. J., "On the statistics of cognitive radio capacity in shadowing and fast fading environments," *IEEE Transactions on Wireless Communications*, vol. 9, no. 2, pp. 844-852, 2010.
- [87] Ho M., Berber S., and Sowerby K., "Building leakage propagation measurements for indoor cognitive radio systems," *Electronics Letters*, vol. 48, no. 23, pp. 1508-1510, 2012.
- [88] Hamid S., *et al.*, "Indoor-to-outdoor channel characterization for modeling and prediction of interference in next generation wireless networks," in *European Conference on Antennas and Propagation*, Lisbon, 2015, pp. 1-5.
- [89] EURO-COST231, "Urban Transmission Loss Models for Mobile Radio in the 900 and 1800 MHz Bands," The Hague, 1991.
- [90] Ikegami F., Takeuchi T., and Yoshida S., "Theoretical prediction of mean field strength for urban mobile radio," *IEEE transactions on Antennas and Propagation*, vol. 39, no. 3, pp. 299-302, 1991.
- [91] Xing X., *et al.*, "Spectrum prediction in cognitive radio networks," *IEEE Wireless Communications*, vol. 20, no. 2, pp. 90-96, 2013.

- [92] Shu Y., *et al.*, "Wireless traffic modeling and prediction using seasonal ARIMA models," in *IEEE Int. Conf. on Commun.*, Anchorage, 2003, pp. 1675-1679.
- [93] Wang W. and Niu Z., "Time series analysis of NASDAQ composite based on seasonal ARIMA model," in *Int. Conf. on Manage. and Service Sci.*, Wuhan, 2009, pp. 1-4.
- [94] Tran V. G., Debusschere V., and Bacha S., "Hourly server workload forecasting up to 168 hours ahead using Seasonal ARIMA model," in *IEEE Int. Conf. on Ind. Technology*, Athens, 2012, pp. 1127-1131.
- [95] Wang Z. and Salous S., "Time series arima model of spectrum occupancy for cognitive radio," in *Seminar on Cognitive Radio and Software Defined Radios: Technologies and Techniques*, London, 2008, pp. 1-4.
- [96] Gorcin A., *et al.*, "An autoregressive approach for spectrum occupancy modeling and prediction based on synchronous measurements," in *Int. Symp. on Personal Indoor and Mobile Radio Commun.*, Toronto, 2011, pp. 705-709.
- [97] Yarkan S. and Arslan H., "Binary time series approach to spectrum prediction for cognitive radio," in *Vehicular Technology Conf.*, Dublin, 2007, pp. 1563-1567.
- [98] Box G., Jenkins G., and Reinsel C., *Time Series Analysis: Forecasting and Control*, 4th ed. New Jersey: Wiley, 2008.
- [99] Permanasari A. E., Hidayah I., and Bustoni I., "SARIMA (Seasonal ARIMA) implementation on time series to forecast the number of Malaria incidence," in *Int. Conf. on Inform. Technology and Electrical Engineering*, Yogyakarta, 2013, pp. 203-207.
- [100] Pedraza L., Hernandez C., and Rodriguez E., "Modeling of GSM Spectrum Based on Seasonal ARIMA model," in *6th IEEE Latin-American Conference on Communications*, Cartagena de Indias, 2014, pp. 1-4.
- [101] Mahram A. and Shayesteh M. G., "Blind wideband spectrum sensing in cognitive radio networks based on direction of arrival estimation model and generalised autoregressive conditional heteroscedasticity noise modelling," *IET Communications*, vol. 8, no. 18, pp. 3271-3279, 2014.
- [102] Anand N. C., Scoglio C., and Natarajan B., "GARCH - non-linear time series model for traffic modeling and prediction," in *IEEE Network Operations and Management Symposium*, Salvador, 2008, pp. 694-697.
- [103] Tran Q., *et al.*, "A Multiplicative Seasonal ARIMA/GARCH Model in EVN Traffic Prediction," *Int. J. Communications, Network and System Sciences*, vol. 8, pp. 43-49, 2015.
- [104] Zhanga Y., *et al.*, "A Garch-based adaptive playout delay algorithm for VoIP," *Computer Networks*, vol. 54, no. 17, pp. 3108-3122, 2010.
- [105] Kim S., "Forecasting internet traffic by using seasonal GARCH models," *Journal of Communications and Networks*, vol. 13, no. 6, pp. 621-624, 2011.
- [106] Engle R., "The Use of ARCH/GARCH Models in Applied Econometrics," *Journal of Economic Perspectives*, vol. 15, no. 4, pp. 157-168, 1982.
- [107] Bollerslev T., "Generalized autoregressive conditional heteroskedasticity," *Journal of Econometrics*, vol. 31, no. 3, pp. 307-327, 1986.
- [108] Edward N., "Modelling and Forecasting Using Time Series Garch Models: An Application of Tanzania Inflation Rate Data," Master of Science, University of Dar es-Salaam, Tanzania, 2011.
- [109] Chinomona A., "Time Series Modelling with Application to South African Inflation Data," Master of Science in Statistics, University of KwaZulu-Natal, Pietermaritzburg, 2009.
- [110] Talke I., "Modelling volatility in time series data," Master of Science, University of KwaZulu-Natal, Pietermaritzburg, 2003.

- [111] Gouriéroux C. and Monfort A., *Time Series and Dynamic Models*, 1st ed. Cambridge: Cambridge University Press, 1997.
- [112] Pedraza L., Hernandez C., and Paez I., "Evaluation of nonlinear forecasts for radioelectric spectrum," *International Journal of Engineering and Technology*, vol. 8, no. 3, pp. 1611-1626, 2016.
- [113] Yang L., *et al.*, "Spectrum usage prediction based on high-order markov model for cognitive radio networks," in *Int. Conf. on Comput. and Inform. Technology*, Bradford, 2010, pp. 2784-2788.
- [114] Black T., Kerans B., and Kerans A., "Implementation of hidden markov model spectrum prediction algorithm," in *Int. Symp. on Commun. and Inform. Technologies*, Gold Coast, 2012, pp. 280-283.
- [115] Bednarczyk W. and Gajewski P., "Hidden Markov Models Based Channel Status Prediction for Cognitive Radio Networks," in *PIERS Proceedings*, Prague, 2015, pp. 2770-2773.
- [116] Tumuluru V., Wang P., and Niyato D., "Channel status prediction for cognitive radio networks," *Wireless Communications and Mobile Computing*, vol. 12, no. 10, pp. 862-874, 2012.
- [117] Lopez M. and Casadevall F., "Empirical Time-Dimension Model of Spectrum Use Based on a Discrete-Time Markov Chain With Deterministic and Stochastic Duty Cycle Models," *IEEE Transactions on Vehicular Technology*, vol. 60, no. 6, pp. 2519-2533, 2011.
- [118] Erlwein C., "Applications of hidden Markov models in financial modelling," Doctor of Philosophy, Department of Mathematical Sciences, Brunel University, London, 2008.
- [119] Norris J., *Markov Chains*, 1st ed. Cambridge: Cambridge University Press, 1997.
- [120] Hamilton J., *Time Series Analysis*, 1st ed. New Jersey: Princeton University Press, 1994.
- [121] Zakai M., "On the optimal filtering of diffusion processes," *Zeitschrift für Wahrscheinlichkeitstheorie und Verwandte Gebiete*, vol. 11, no. 3, pp. 230-243, 1969.
- [122] Elliott R., Aggoun L., and Moore J., *Hidden Markov Models Estimation and Control* vol. 29. New York: Springer-Verlag, 1995.
- [123] Hull J. and White A., "Pricing Interest-Rate-Derivative Securities," *Review of Financial Studies*, vol. 3, no. 4, pp. 573-592, 1990.
- [124] McLachlan G. and Krishnan T., *The EM Algorithm and Extensions*, 2nd ed. New Jersey: Wiley, 2008.
- [125] Elliott R. J. and Krishnamurthy V., "New finite-dimensional filters for parameter estimation of discrete-time linear Gaussian models," *IEEE Transactions on Automatic Control*, vol. 44, no. 5, pp. 938-951, 1999.
- [126] Wu C. F. J., "On the Convergence Properties of the EM Algorithm," *The Annals of Statistics*, vol. 11, no. 1, pp. 95-103, 1983.
- [127] Benyacoub B., *et al.*, "Initial Model Selection for the Baum-Welch Algorithm Applied to Credit Scoring," in *Modelling, Computation and Optimization in Information Systems and Management Sciences*. vol. 360, ed Nancy: Springer, 2015, pp. 359-368.
- [128] Cappé O., Moulines E., and Ryden T., *Inference in Hidden Markov Models*, 1st ed. New York: Springer-Verlag, 2005.
- [129] Yu C., He Y., and Quan T., "Frequency Spectrum Prediction Method Based on EMD and SVR," in *Intelligent Systems Design and Applications*, Kaohsiung, 2008, pp. 39-44.

- [130] Huang N. E., *et al.*, "The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis," in *Proceedings of the Royal Society*, London, 1998, pp. 903-995.
- [131] Magrin I. and Baraniuk R., "Empirical Mode Decomposition based time-frequency attributes," in *SEG Meeting*, Houston, 1999.
- [132] Li D. and Cao Y., "SOFM based support vector regression model for prediction and its application in power system transient stability forecasting," in *International Power Engineering Conference*, Singapore, 2005, pp. 765-770.
- [133] Dufrenois F. and Hamad D., "Fuzzy weighted support vector regression for multiple linear model estimation : application to object tracking in image sequences," in *International Joint Conference on Neural Networks*, Orlando, 2007, pp. 1289-1294.
- [134] Xie Y., *et al.*, "Phase-space reconstruction of ECoG time sequences and extraction of nonlinear characteristic quantities," *Acta Physica Sinica*, vol. 51, no. 2, pp. 205-214, 2002.
- [135] Shukuan L., *et al.*, "Phase Space Reconstruction of Nonlinear Time Series Based on Kernel Method," in *The Sixth World Congress on Intelligent Control and Automation*, Dalian, 2006, pp. 4364-4368.
- [136] Wei K., Li Y., and Zhang P., "Analysis and Application of Time Series Forecasting Model via Support Vector Machines," *Systems Engineering and Electronics*, vol. 27, no. 3, pp. 529-532, 2005.
- [137] Bai S., Zhou X., and Xu F., ""Soft decision" spectrum prediction based on back-propagation neural networks," in *International Conference on Computing, Management and Telecommunications*, Da Nang, 2014, pp. 128-133.
- [138] Bai S., Zhou X., and Xu F., "Spectrum prediction based on improved-back-propagation neural networks," in *International Conference on Natural Computation*, Zhangjiajie, 2015, pp. 1006-1011.
- [139] Kunwei L., *et al.*, "A spectrum prediction approach based on neural networks optimized by genetic algorithm in cognitive radio networks," in *International Conference on Wireless Communications, Networking and Mobile Computing*, Beijing, 2014, pp. 131-136.
- [140] Iliya S., *et al.*, "Optimized artificial neural network using differential evolution for prediction of RF power in VHF/UHF TV and GSM 900 bands for cognitive radio networks," in *Workshop on Computational Intelligence*, Bradford, 2014, pp. 1-6.
- [141] Chen Y. and Oh H. S., "Spectrum measurement modelling and prediction based on wavelets," *IET Communications*, vol. 10, no. 16, pp. 2192-2198, 2016.
- [142] Zhang Q. and Benveniste A., "Wavelet networks," *IEEE Transactions on Neural Networks*, vol. 3, no. 6, pp. 889-898, 1992.
- [143] Daubechies I., *Ten Lectures on Wavelets*, 8th ed. Philadelphia: SIAM, 2004.
- [144] Veitch D., "Wavelet Neural Networks and their application in the study of dynamical systems," Master thesis, Department of Mathematics, University of York, York, 2005.
- [145] Akujuobi C. M., *et al.*, "Wavelet-based differential nonlinearity testing of mixed signal system ADCs," in *IEEE Proceedings in SoutheastCon*, Richmond, 2007, pp. 76-81.
- [146] Chun-Lin L., "A tutorial of the wavelet transform," National Taiwan University, 2010.
- [147] Frimpong E. and Okyere P., "Monthly energy consumption forecasting using wavelet analysis and radial basis function neural network," *Journal of Science and Technology*, vol. 30, no. 2, pp. 157-163, 2010.

- [148] Li J., *et al.*, "Brief Introduction of Back Propagation (BP) Neural Network Algorithm and Its Improvement," in *Advances in Computer Science and Information Engineering*. vol. 2, ed New York: Springer, 2012, pp. 553-558.
- [149] Pedraza L., Forero F., and Paez I., "Evaluación de ocupación del espectro radioeléctrico en Bogotá-Colombia," *Ingeniería y Ciencia*, vol. 10, no. 19, pp. 127-143, 2014.
- [150] Pedraza L., *et al.*, *Ocupación espectral y modelo de radio cognitiva para Bogotá*, 1st ed. Bogotá: Universidad Distrital Francisco José de Caldas, 2016.
- [151] ITU-R, "Report ITU-R SM.2256, spectrum occupancy measurements and evaluation," Geneva, 2012.
- [152] Digham F., Alouini M. S., and Simon M., "On the Energy Detection of Unknown Signals Over Fading Channels," *IEEE Transactions on Communications*, vol. 55, no. 1, pp. 21-24, 2007.
- [153] Clegg R., "A practical guide to measuring the Hurst parameter," *International Journal of Simulation: Systems, Science & Technology*, vol. 7, no. 2, pp. 3-14, 2006.
- [154] Hyndman R., *et al.*, *Forecasting with Exponential Smoothing: The State Space Approach*, 1st ed. Berlin: Springer-Verlag Berlin Heidelberg, 2008.
- [155] Dickey D. A. and Fuller W. A., "Distribution of estimators for autoregressive time series with a unit root," *J. of the Amer. Statistical Assoc*, vol. 74, no. 366, pp. 427-431, 1979.
- [156] Bozdogan H., "Model selection and Akaike's Information Criterion (AIC): The general theory and its analytical extensions," *Psychometrika*, vol. 52, no. 3, pp. 345-370, 1987.
- [157] Debnath L. and Shah F., *Wavelet Transforms and Their Applications*, 2nd ed. New York: Birkhäuser, 2014.
- [158] Madsen K., Nielsen H. B., and Tingleff O., *Methods for Non-linear Least Squares Problems*, 2nd ed. Kongens Lyngby: Informatics and Mathematical Modelling, Technical University of Denmark, 2004.
- [159] Lopez M. and Casadevall F., "Space-dimension models of spectrum usage for cognitive radio networks," *IEEE Transactions on Vehicular Technology*, 2016.
- [160] Egan W. F., *Practical RF System Design*, 1st ed. New Jersey: Wiley, 2003.